

АЛГОРИТМ НА ОСНОВЕ МОДЕЛИ ПЕРЕДАТОЧНОЙ ФУНКЦИИ И ОДНОКЛАССОВОЙ КЛАССИФИКАЦИИ ДЛЯ ОБНАРУЖЕНИЯ АНОМАЛЬНОГО СОСТОЯНИЯ ДАМБ

А. П. Козионов^{а, б}, инженер, аспирант

А. Л. Пяйт^а, ведущий инженер, канд. техн. наук

И. И. Мохов^а, ведущий эксперт-исследователь

Ю. П. Иванов^б, канд. техн. наук, доцент

^аООО Сименс, департамент корпоративных технологий, Санкт-Петербург, РФ

^бСанкт-Петербургский государственный университет аэрокосмического приборостроения, Санкт-Петербург, РФ

Постановка проблемы: как правило, мониторинг состояния дамб с использованием датчиков, установленных в дамбу, заключается в сравнении измерений датчиков с заранее определенными пороговыми значениями, полученными в результате анализа или моделирования структуры дамбы. Этот способ позволяет обнаружить лишь простые случаи разрушения дамбы, например переливание гребня дамбы. Более сложные случаи, вызванные процессами внутренней эрозии, такой способ обнаружить не позволяет. **Цель:** разработка и апробация алгоритма обнаружения аномального состояния дамбы, вызванного процессами внутренней эрозии. **Результаты:** предлагаемый алгоритм обнаружения аномального состояния основан на моделировании передаточной функции между измеряемыми сигналами уровня воды и порового давления внутри дамбы. Одноклассовый классификатор «нейронные облака» используется для оценки нелинейной, нечеткой функции принадлежности ошибки модели к области нормального состояния. Обучение классификатора «нейронные облака» производится на исторических данных о нормальном поведении дамбы, полученных с датчиков, установленных в дамбу. Нечеткий выход классификатора, изменяющийся от 0 до 1, позволяет давать оценку близости текущего состояния дамбы к аномальному. Апробация алгоритма проводилась на реальных данных, полученных в ходе натурного эксперимента. **Практическая значимость:** результаты исследований и алгоритмические решения использованы компанией «Сименс» в компоненте искусственного интеллекта при разработке системы мониторинга состояния дамб.

Ключевые слова — обнаружение аномалий, мониторинг состояния дамб, интеллектуальная обработка сигналов, передаточная функция, нейронные облака, одноклассовая классификация.

Введение

В настоящее время более чем две трети европейских городов постоянно находятся под риском затопления. Число зарегистрированных наводнений увеличилось в четыре раза по сравнению с 80-ми годами XX века [1]. Изменение климата и быстрая урбанизация еще сильнее усугубляют проблему.

Большое число наводнений вызвано прорывом систем защиты от наводнений — дамб и плотин [2]. Например, в Нидерландах с 1134 по 2006 г. было зарегистрировано примерно 1735 случаев разрушения дамб [3]. В Европе существует 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 обходят тысячи 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 насыпных дамб заключается в сложном поведении дамбы и, как следствие, измеряемых параметров системы. Это влечет необходимость детального исследования объекта мониторинга и моделирования большого числа возможных сценариев разрушения дамбы, что требует больших затрат и не всегда возможно.

В 2012 г. в рамках исследовательской программы IJkDijk [7] была проведена серия экспериментов, направленных на исследование механизмов разрушения дамб, средств предотвращения разрушения дамб, систем и датчиков для мониторинга состояния дамб, а также алгоритмов для обнаружения аномального состояния дамб. Для экспериментов было сооружено три дамбы, каждая имела свое название: «Южная дамба», «Западная дамба», «Восточная дамба».

В настоящей работе авторами представлен алгоритм обнаружения аномального состояния дамбы на основе модели передаточной функции (ПФ) между сигналами уровня воды и порового давления (давления воды в порах почвы) в дамбу.

Апробация алгоритма проведена на реальных данных эксперимента по анализу влияния процессов эрозии на устойчивость дамбы, полученных в ходе эксперимента «Восточная дамба».

Подход к обнаружению аномального состояния дамб

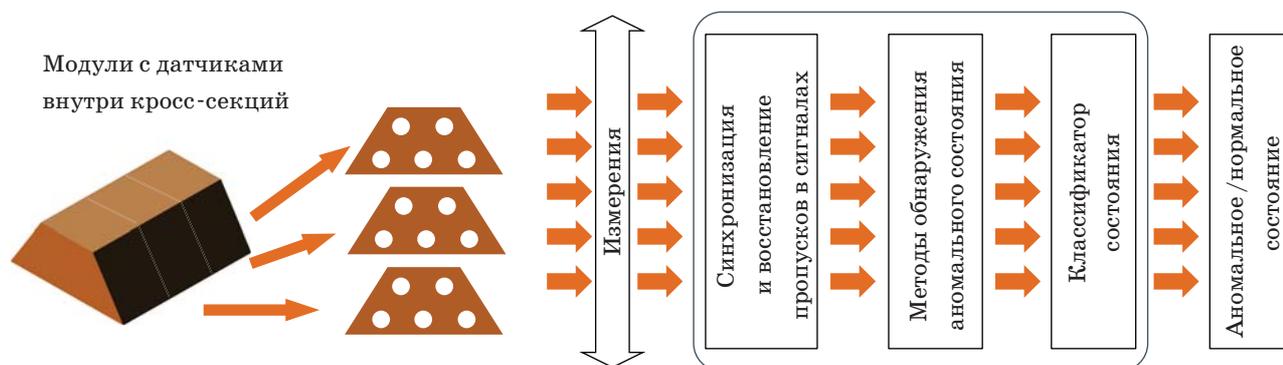
Мониторинг состояния дамбы осуществляется путем анализа измерений, собранных с сети различных датчиков, установленных в дамбу, таких как датчики порового давления и температуры, инклинометры. Задача системы мониторинга — обнаружить аномальное состояние дамбы. Под аномальным состоянием (поведением) подразумевается отклонение от нормального состояния объекта, которое может привести к неисправности или разрушению дамбы [8]. Датчики устанавливаются в каждую кросс-секцию дамбы. Такое деление объекта мониторинга позволяет локализовать аномальное состояние и предотвращает избыточность измерений. Применение сетей датчиков как части системы раннего предупреждения в рамках проекта UrbanFlood описано в работах [9–11].

Различные типы измеряемых параметров обрабатываются в соответствии с их свойствами. Например, в случае датчиков порового давления необходимо учитывать зависимость между измерениями порового давления в разных точках дамбы. Для анализа и мониторинга зависимостей между сигналами можно использовать ПФ или методы, которые позволяют оценивать границы областей нормального поведения. В первом случае существует проблема идентификации ПФ, а также проблема устойчивости [12]. Во втором случае алгоритмы, основанные на оценивании допусков для параметров, не имеют проблем, связанных с устойчивостью и идентификацией, но не обнаруживают скрытые в сигналах зависимости, а лишь позволяют обнаружить превышение сигналами критических значений. Следствием является то, что аномальные состояния, прояв-

ляющиеся в динамике сигналов, не будут обнаружены. Ранее авторами был представлен алгоритм на основе применения граничных методов для совместного анализа реальных сигналов и сигналов, сгенерированных моделью на основе метода конечных элементов [13], но данный алгоритм требует построения модели дамбы и моделирования сценариев ее поведения, что не всегда возможно.

Основная идея предлагаемого подхода заключается в применении методов обнаружения аномального поведения, которые обучаются на «сырых» и (или) предварительно обработанных данных [10, 14]. 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 [14, 15]. Обнаружение аномального состояния состоит из трех этапов (рис. 1). Первый этап — сбор данных с датчиков. Второй этап — их предварительная обработка, в нашем случае — восстановление пропусков в данных алгоритмом на основе метода «Гусеница-SSA» (Singular Spectrum Analysis — спектрально-сингулярный анализ) или модели авторегрессии [14, 15]. На третьем этапе с помощью алгоритма обнаружения аномального состояния извлекается информация из сигналов (признаки). Далее алгоритмы классификации, основанные на методах машинного обучения, определяют состояние дамбы.

Поскольку для дамбы зачастую доступны лишь данные о нормальном состоянии, классификацию состояния дамбы логично производить, оценивая степень принадлежности сигналов датчиков к области нормального состояния. Для решения такой задачи применимы алгоритмы одноклассовой классификации, основанные на оценке принадлежности сигнала к одному заданному классу. В нашем случае это область «исторических» измерений, соответствующих нормальному состоянию дамбы.



■ Рис. 1. Этапы обнаружения аномального состояния дамбы

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 работе рассматривается классификатор «нейронные облака» [15].

Наиболее часто для задач обнаружения аномалий используют различные метрики расстояний (евклидову, Махаланобиса и др.) [16], методы на основе оценки плотности вероятности данных, например гауссовы смеси (Gaussian Mixture Models — GMM) [16], которые оценивают плотность вероятности для данных, соответствующих нормальному состоянию. Общий недостаток этих методов в том, что они сами по себе не являются классификаторами, и их выход все равно нужно каким-то образом классифицировать [17]. Также стоит отметить одноклассовый метод опорных векторов (one-class SVM — Support Vector Machines) [16]. Недостаток метода в том, что он оценивает четкую границу класса, которую нельзя перенастроить (скорректировать) во время использования классификатора, а лишь только при новом переобучении.

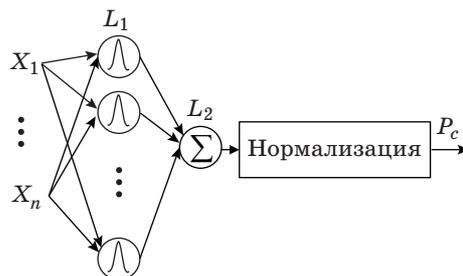
«Нейронные облака» оценивают нелинейную, нечеткую функцию принадлежности (инкапсулятор) данных к области нормального состояния для исходного «нормального» множества признаков. Затем функция принадлежности используется для оценки принадлежности новых экземпляров данных к области нормального поведения. Выход «нейронных облаков» — значение от 0 до 1. Значения, близкие к 1, отражают нормальное поведение, а близкие к 0 — аномальное. Таким образом, «нейронные облака» позволяют давать оценку близости текущего состояния к аномальному, что может быть использовано при принятии решения.

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

Метод АКМ — это модификация хорошо известного метода k-средних с возможностью адаптивного расчета оптимального числа кластеров при заданном максимальном числе кластеров (центроидов). АКМ состоит из трех шагов, выполняющихся итеративно.

Шаг 1. Задается начальное максимальное и минимальное число центроидов.

Шаг 2. Вызывается алгоритм k-средних.



■ **Рис. 2.** «Нейронные облака»: L_1 — РБФ; L_2 — суперпозиция РБФ; P_c — значение функции принадлежности

Шаг 3. Анализируются центроиды, полученные после алгоритма k-средних. Добавляется или убирается центроид, исходя из следующих условий:

- если дистанция до данных выше заданной, то создается новый центроид;
- если кластер состоит из меньшего числа точек, чем задано, то он убирается;
- если расстояние между центроидами меньше заданного, то кластеры объединяются;
- останов, если первые три условия не выполняются.

Выход алгоритма АКМ — это центроиды кластеров, представляющих собой нормальное состояние объекта. После того как все центроиды получены, данные инкапсулируются функцией принадлежности. Для данных задачи используются РБФ

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

где x — входные данные; m_i — среднее (центр) РБФ; σ — среднеквадратическая ошибка (СКО) (ширина) РБФ.

Центроиды, полученные от АКМ, становятся центрами соответствующих РБФ. Сумма всех колоколов дает функцию принадлежности (рис. 2). Нормализация применяется для того, чтобы получить выходное значение функции принадлежности в интервале от 0 до 1.

Алгоритм обнаружения аномального состояния дамбы на основе моделирования ПФ между сигналами

Аномалии в состоянии дамбы, вызванные эрозией (внутренней или внешней), могут быть обнаружены датчиками порового давления. Если, например, переливание гребня дамбы может быть обнаружено при сравнении уровня воды с пороговым, то более сложные аномалии, вызванные процессами внутренней эрозии, могут быть обнаружены путем более сложного анализа зависимостей между сигналами уровня воды и давления воды в порах почвы (порового давления).

Для анализа зависимостей между сигналами можно использовать ПФ, которые выражают связь между входом и выходом системы. Передаточные функции могут быть как линейные, так и нелинейные (нейронные сети, нечеткие ПФ, полиномиальные, вейвлетные и т. д.). Применение линейной ПФ имеет ряд преимуществ: это относительно простота модели; возможность априорной оценки устойчивости модели по средствам анализа ее коэффициентов (что не получится сделать для нелинейной модели); при оценивании коэффициентов линейной модели есть только одно оптимальное решение, в отличие, например, от нейронных сетей, где может быть несколько минимумов при одной и той же структуре модели. Поэтому если зависимость адекватно аппроксимируется линейной ПФ, то предпочтительно использовать ее.

Модель линейной ПФ — это дифференциальный оператор, выражающий связь между входом и выходом линейной стационарной системы. Модель ПФ может быть записана в виде разностного уравнения [17]

$$y(t) = b_1 u(t - n_k) + \dots + b_{n_b} u(t - n_k - n_b + 1) - a_1 y(t - 1) - \dots - a_n y(t - n_a) + e(t),$$

где $y(t)$ — выход системы (сигнал); $u(t)$ — вход системы; t — отсчеты времени; a и b — коэффициенты выхода и входа соответственно; n_a и n_b — количество коэффициентов выхода и входа; n_k — коэффициент задержки входа модели.

Таким образом, данная модель позволяет оценить линейную зависимость выхода системы от входа и предыдущих значений выхода. В иностранной литературе эта модель часто называется ARX-model (autoregressive exogenous model — авторегрессионная модель с внешними входами) [18]. Краткая запись модели ARX(n_a, n_b, n_k) означает, что модель имеет n_a коэффициентов выхода, n_b коэффициентов входа с задержкой в n_k .

Идентификация модели (обучение модели) заключается в нахождении наилучших порядков и коэффициентов модели. Обучается модель на исторических данных сигналов, которые в свою очередь разбиваются на два множества: множество для обучения модели (training set, обычно

принимается 80 % данных) и множество для проверки качества модели (validation set, обычно принимается 20 % данных). Часто для нахождения значений коэффициентов a и b используется метод наименьших квадратов.

В качестве критерия для выбора наилучшей модели можно использовать СКО оценки

$$\sigma = \sqrt{\frac{1}{N_{VAL}} \sum_{t=1}^N (y(t) - \hat{y}(t))^2},$$

где N_{VAL} — количество измерений, используемых в множестве для проверки; $\hat{y}(t)$ — оценка моделью значения $y(t)$.

Другой наиболее часто используемый критерий — информационный критерий Акайке [19], который, в отличие от среднеквадратичной модели, накладывает штраф на размерность модели, что позволяет на выходе получить компактную модель с качеством, приемлемым для решения задачи:

$$AIC = \ln \sigma^2 + \frac{2d}{N_{TR}},$$

где σ — СКО оценки; d — количество параметров модели; N_{TR} — количество измерений, используемых в обучающем множестве.

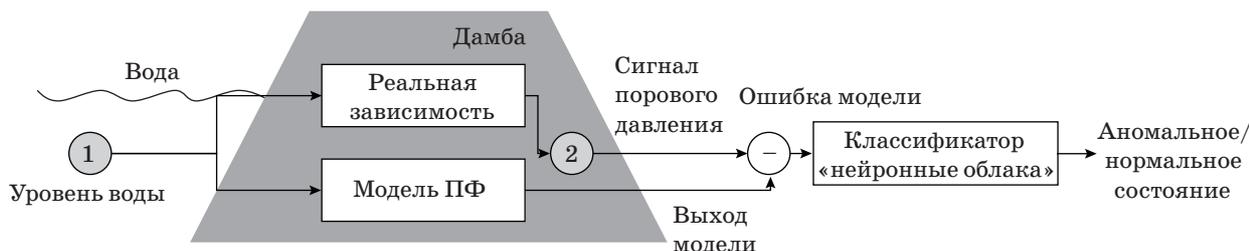
Также используется метрика R^2 , которая рассчитывается следующим образом:

$$R^2 = 1 - \frac{\sigma^2}{\sigma_y^2},$$

где σ — дисперсия ошибки оценки пропущенных значений; σ_y — СКО сигнала. С уменьшением дисперсии ошибки оценки R^2 стремится к 1, с увеличением ошибки оценки R^2 стремится к отрицательным значениям. Таким образом, чем ближе R^2 к 1, тем выше точность модели.

Идентификацию оптимальных параметров моделей можно провести методом перебора, оценивая на каждой итерации значение критерия качества модели.

Идея настоящего алгоритма обнаружения аномального состояния дамбы заключается в оценивании ПФ между сигналами датчиков, установленных в дамбу (рис. 3). Модель оценивается по данным о нормальном состоянии дамбы. Далее



■ Рис. 3. Схема алгоритма

во время мониторинга дамбы проверяется, сохраняется зависимость или нет. Если зависимость не сохраняется и ошибка модели увеличивается, то это — сигнал аномального состояния. Ошибка модели вычисляется как разность между реальным значением сигнала и значением, оцененным моделью для данного момента времени.

В настоящей работе в качестве входа модели будет использоваться сигнал уровня воды, а выходом будет сигнал порового давления. Таким образом, если при изменении уровня воды изменение реального порового давления будет не совпадать с выходом модели и ошибка будет увеличиваться, то это — признак аномального состояния дамбы. Для оценки близости ошибки модели к аномальному состоянию мы будем использовать метод «нейронные облака».

Описание эксперимента

Эксперимент «Восточная дамба» был разработан для исследования механизмов разрушения дамбы (рис. 4, слева), вызванных эрозией [7]. Дамба состояла из слоев песка и глины (рис. 5). В дамбу была установлена сеть модулей многопараметрических датчиков, измеряющих поровое давление, отклонение (инклинометры) и температуру [20]. Датчики были установлены в песчаный слой в два ряда вдоль внешнего откоса дамбы.

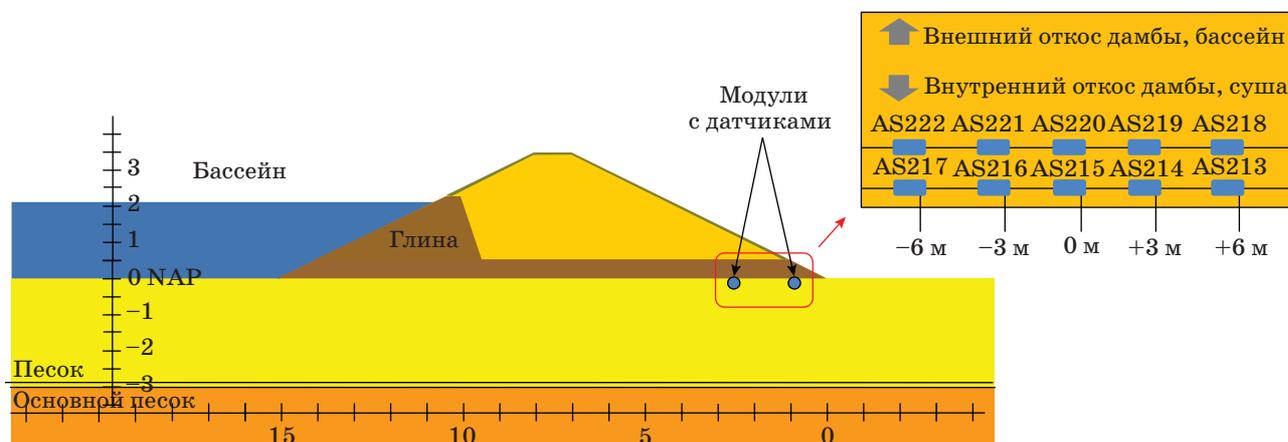
Первый ряд: датчики AS 218–AS 222; второй ряд: датчики AS 213–AS 217. Также измерялся уровень воды в бассейне.

В течение эксперимента уровень воды в бассейне увеличивался ступенчато (рис. 6, а), что приводило к ступенчатому нарастанию порового давления $P_{п}$, измеряемого датчиками (рис. 6, б).

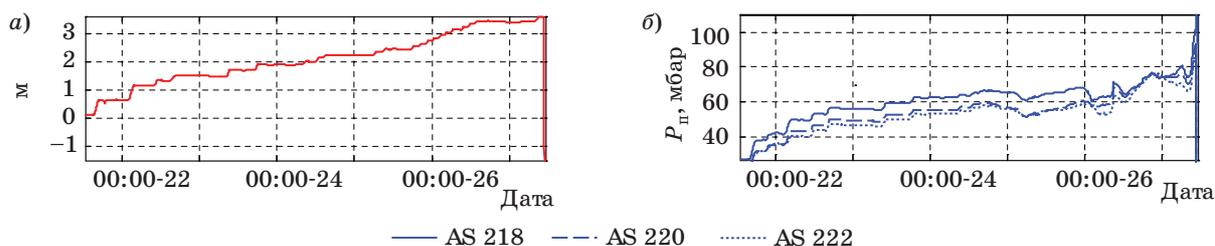
Эксперимент состоял из трех этапов. Первый этап — повышение уровня воды в бассейне для моделирования процесса вымывания грунта, если процесс вымывания грунта не начался; второй этап — повышение уровня воды в целях модели-



■ Рис. 4. «Восточная дамба» (слева) и «Западная дамба» (справа) после окончания экспериментов



■ Рис. 5. Схема дамбы



■ Рис. 6. Измерения датчика уровня воды в бассейне (а) и датчиков порового давления (б); формат даты: ЧЧ:ММ-ДД

рования переливания воды через слой глины; третий этап — увеличение уровня воды в целях переливания воды через гребень дамбы.

Эксперимент начался 21.08.2012 в 15:20. Первые просачивания воды и вымывание грунта были обнаружены 26.08.2012 в 15:17, в этот момент уровень воды достигал трех метров. Трещины вдоль гребня дамбы, вызванные эрозией, появились 27.08.2012 в 10:10, в этот момент уровень воды в бассейне был равен 3,2 м.

Прорыв дамбы произошел возле датчиков AS 218 и AS 213. Причиной разрушения дамбы явилось внутреннее переливание (переливание внутреннего глиняного слоя), вызванное процессами внутренней эрозии и вымывания грунта.

Моделирование алгоритма на экспериментальных данных

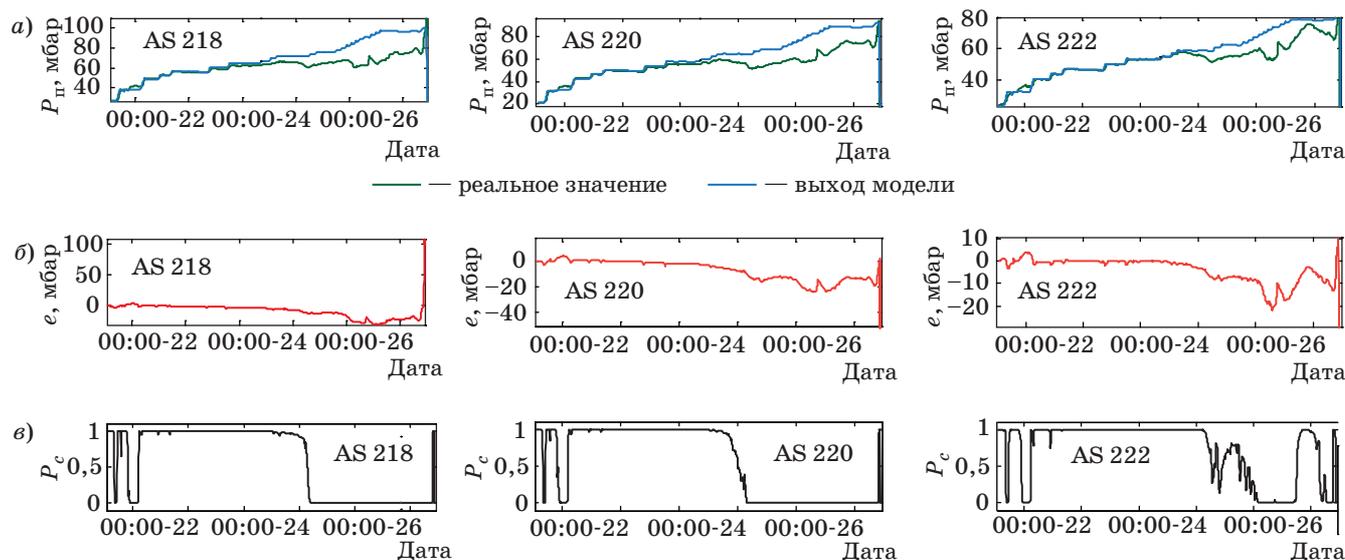
Моделирование алгоритма проводилось на реальных данных, полученных от трех пар датчиков в результате эксперимента. Входом ПФ был уровень воды в бассейне, выходом — измерения датчиков порового давления $P_{п}$ AS 218 – AS 222 (рис. 7, а), частота измерений — один раз в две минуты. Измерения датчиков не содержали пропусков, поэтому не потребовалось применять алгоритмы восстановления пропусков.

В соответствии с алгоритмом поровое давление было смоделировано с помощью ПФ. Для обучения ПФ были выбраны первые 25 % измерений датчиков (сделано это с целью не включить последующее развивающееся аномальное состояние в обучающее множество). Идентификация модели была проведена посредством перебора: для

порядков n_a и n_b — от 1 до 50, для порядка задержки n_k — от 0 до 50, — и расчета информационного критерия Акайке; оптимальной моделью оказалась модель с порядками $n_a = 0$, $n_b = 1$, $n_k = 5$. Низкий порядок модели может быть объяснен квазистационарным поведением сигналов без колебаний, соответствующих, например, приливам и отливам воды [12]. Параметр задержки n_k , равный пяти отсчетам (10 мин), означает, что изменение уровня воды влияет на изменение порового давления в датчиках с задержкой в 10 мин. Значения СКО и модели, критерия Акайке и R^2 соответственно равны: $\sigma = 1,37$ мбар, $AIC = 0,63$, $R^2 = 0,98$. Высокие значения показателей точности говорят о том, что линейная модель адекватно описывает зависимости.

Для всех пар датчиков разница e между реальным и смоделированным (ошибка модели) значениями увеличивается с развитием аномального состояния после 24.08.2012 (внутренняя эрозия, рис. 7, б). Для обучения нейронных облаков использовались первые 25 % отсчетов вектора ошибки модели для оценки функции принадлежности к нормальному поведению ошибки модели. Значение функции принадлежности «нейронных облаков» приближается к 0 с развитием аномалии. Порог для значения функции принадлежности нейронных облаков, ниже которого предполагается аномальное состояние дамбы, был принят равным 0,8.

Два первых интервала, где значение функции принадлежности около 0, интерпретированы как неизвестное поведение в начале эксперимента. Последующее увеличение ошибки модели e (см. рис. 7, б) и падение значения функции принад-



■ Рис. 7. Результат обнаружения аномального поведения с использованием ПФ: а — сравнение реальных измерений и смоделированных; б — ошибка моделирования; в — значения функции принадлежности «нейронных облаков»

лежности к 0 соответствуют аномальному состоянию дамбы. Для датчиков AS 218 и AS 222 после 25.08.2012 в 2:00 значение функции принадлежности уменьшается до 0,8 и далее до 0, для датчика AS 220 — после 24.08.2012 в 23:00 (рис. 7, в).

Поскольку прорыв дамбы произошел 27.08.2012 в 11:30, а алгоритм позволил обнаружить критическое состояние 25.08.2012 в 2:00, это говорит о том, что аномальное состояние было спрогнозировано за ~55 ч до начала разрушения дамбы, в то время как визуально вымывание грунта было обнаружено 26.08.2012 в 15:17, что соответствует ~37 ч до начала разрушения дамбы.

Заключение

Серия экспериментов IJkDijk была проведена в августе–сентябре 2012 года в Нидерландах. Различные типы датчиков были апробированы во время тестов All-in-one Sensor Validation Test (AIO-SVT) для проверки их применимости и чувствительности к обнаружению различных механизмов разрушения дамб. В настоящей работе рассматривались измерения датчиков порового давления.

Авторами представлено применение алгоритма обнаружения аномального состояния дамбы на основе моделирования ПФ между сигналами и классификации ошибки модели методом «нейронные облака». Алгоритм был разработан в рамках общего подхода к обнаружению аномального

состояния дамб. Апробация алгоритма проводилась на реальных экспериментальных данных. В работе показано, что моделирование ПФ между уровнем воды и поровым давлением позволяет обнаружить аномальное состояние дамбы, вызванное процессами внутренней эрозии, на начальных этапах его зарождения. Высокие значения показателей точности говорят о том, что линейная модель адекватно описывает зависимости в сигналах. Предлагаемый алгоритм позволил обнаружить аномальное состояние дамбы за ~55 ч до ее прорыва, в то время как визуально вымывание грунта было обнаружено за ~37 ч до прорыва дамбы.

Стоит отметить, что алгоритм имеет ограничения. Во-первых, не всегда можно идентифицировать адекватную модель ПФ в случае сложных зависимостей. Во-вторых, модель может иметь большую ошибку из-за того, что текущий вид поведения сигналов отсутствовал в обучающем множестве, и, как следствие, это может привести к ложному обнаружению аномального состояния. Для предотвращения таких ложных срабатываний необходимо периодически либо адаптивно, с увеличением числа ложных срабатываний, переобучать модель.

Результаты исследований и алгоритмические решения использованы компанией «Сименс» в компоненте на основе искусственного интеллекта при разработке системы мониторинга состояния дамб.

Литература

1. Flood — Data and Statistics. <http://www.prevention-web.net/english/hazards/statistics/?hid=71> (дата обращения: 01.08.2015).
2. Wohl E. Inland Flood Hazards: Human, Riparian, and Aquatic Communities. — Cambridge, Cambridge University Press, 2000. — 518 p.
3. Baars S., Kempen M. The Causes and Mechanisms of Historical Dike Failures in the Netherlands. — Official Publication of the European Water Association, 2009. — 14 p.
4. FLOODsite project. <http://www.floodsite.net/> (дата обращения: 01.08.2015).
5. FloodControl 2015. <http://www.floodcontrol2015.com/> (дата обращения: 01.08.2015).
6. UrbanFlood project. <http://www.urbanflood.eu> (дата обращения: 01.08.2015).
7. IJkDijk project. <http://www.floodcontrolijkdijk.nl/> (дата обращения: 01.08.2015).
8. Isermann R. Fault-Diagnosis Systems: an Introduction from Fault Detection to Fault Tolerance. — Berlin, Berlin Springer, 2006. — 475 p.
9. Krzhizhanovskaya V. V., et al. Flood Early Warning System: Design, Implementation and Computational

- Modules // Procedia Computer Science. 2011. N 4. P. 106–115. doi:10.1016/j.procs.2011.04.012
10. Simm J., et al. Interpreting Sensor Measurements in Dikes — Experiences from Urbanflood Pilot Sites // Comprehensive Flood Risk Management: Proc. of the 2nd European Conf. on FLOODrisk Management/Klijn & Schweckendiek (ed.). 2012. P. 327–336. doi:10.1201/b13715-47
11. Pyayt A. L., et al. Machine Learning Methods for Environmental Monitoring and Flood Protection // World Academy of Science, Engineering and Technology. 2011. N 5. P. 118–123.
12. Pyayt A. L., et al. Data-Driven Modelling for Flood Defence Structure Analysis // Comprehensive Flood Risk Management/Klijn & Schweckendiek (ed.). 2013. P. 301–306.
13. Pyayt A. L., et al. Combining Data-Driven Methods with Finite Element Analysis for Flood Early Warning Systems // Intern. Conf. on Computational Science, ICCS 2015 «Computational Science at the Gates of Nature». 2015. N 51. P. 2347–2356. doi:10.1016/j.procs.2015.05.404
14. Козионов А. П., Пяйт А. Л., Мохов И. И., Иванов Ю. П. Вейвлет-преобразование и одноклассовая классификация для мониторинга состояния дамб //

- Информационно-управляющие системы. 2014. № 4(71). С. 24–31.
15. 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. doi: 10.5862/JCSTCS.217-222.8
16. Lang B., et al. Neural Clouds for Monitoring of Complex Systems // Optical Memory and Neural Networks. 2008. Vol. 3. N 17. P. 183–192. doi: 10.3103/S1060992X08030016
17. Bishop C. Pattern Recognition and Machine Learning. — N. Y.: Springer, 2006. — 738 p.
18. Box G., Jenkins G. Time Series Analysis: Forecasting and Control. — San Francisco: Holden-Day, 1970. — 573 p.
19. Akaike H. A New Look at the Statistical Model Identification // IEEE Transactions on Automatic Control. 1974. N 19. P. 716–723.
20. Alert Solutions. <http://www.alertsolutions.nl/> (дата обращения: 01.08.2015).

UDC 681.51

doi:10.15217/issn1684-8853.2015.6.10

Algorithm for Dike Abnormal Behavior Detection Based on Transfer Function Model and One-Class ClassificationA. P. Kozionov^{a, b}, R&D Engineer, Post-Graduate Student, alexey.kozionov@gmail.comA. L. Pyayt^a, R&D Leading Engineer, PhD, Computational Science, alexander.pyayt@siemens.comI. I. Mokhov^a, R&D Leading Expert, ilya.mokhov@siemens.comU. P. Ivanov^b, PhD, Tech., Associate Professor, upi@mail.ru^aSiemens, Corporate Technology, 3A, Volynskii St., 191186, Saint-Petersburg, Russian Federation^bSaint-Petersburg State University of Aerospace Instrumentation, 67, B. Morskaya St., 190000, Saint-Petersburg, Russian Federation

Purpose: Dike monitoring with sensors installed in the dike usually assumes that the sensor readings are compared with some pre-defined threshold values derived from the analysis or modeling of the dike structure. This method can detect only the simplest cases of dike failure like crest overtopping, being useless for more complex cases caused by internal erosion. The purpose of this work is developing and testing an algorithm for detecting an abnormal dike condition caused by internal erosion. **Results:** The proposed algorithm is based on the simulation of the transfer function between the measured signals of the water level and the pore pressure inside the dike. A one-class classifier “Neural Clouds” estimates a nonlinear fuzzy membership function which checks whether the model error belongs to the area of normal state of the dike. The classifier is taught on historical data of normal dike behavior obtained from the sensors. The fuzzy response of the classifier varies from 0 to 1, giving an estimation of how close the current state of the dike is to an abnormal state. The algorithm has been tested on natural experimental data. **Practical relevance:** The results and algorithms were used by Siemens in its AI component of a dike condition monitoring system.

Keywords — Anomaly Detection, Dike Health Monitoring, Intelligent Signal Processing, Transfer Function, Neural Clouds, One-Class Classification.

References

1. *Flood — Data and Statistics*. (2015). Available at: <http://www.preventionweb.net/english/hazards/statistics/?hid=71> (accessed 01 August 2015).
2. Wohl E. *Inland Flood Hazards: Human, Riparian, and Aquatic Communities*. Cambridge, Cambridge University Press, 2000. 518 p.
3. Baars S., Kempen M. *The Causes and Mechanisms of Historical Dike Failures in the Netherlands*. Official Publication of the European Water Association, 2009. 14 p.
4. *FLOODsite project*. (2015). Available at: <http://www.floodsite.net/> (accessed 01 August 2015).
5. *FloodControl 2015*. (2015). Available at: <http://www.floodcontrol2015.com/> (accessed 01 August 2015).
6. *UrbanFlood project*. (2015). Available at: <http://www.urbanflood.eu> (accessed 01 August 2015).
7. *IJKDijk project*. Available at: <http://www.floodcontrolijkdijk.nl/> (accessed 01 August 2015).
8. Isermann R. *Fault-Diagnosis Systems: an Introduction from Fault Detection to Fault Tolerance*. Berlin, Berlin Springer, 2006. 475 p.
9. Krzhizhanovskaya V. V., Shirshov G. S., Melnikova N. B., Belleman R. G., Rusadi F. I., Broekhuijsen B. J., Gouldby B. P., Lhomme J., Balis 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 Models. *Procedia Computer Science*, 2011, vol. 4, pp. 106–115. doi:10.1016/j.procs.2011.04.012
10. 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 Urban-flood Pilot Sites. *Proc. of the 2nd European Conf. on FLOODrisk Management “Comprehensive Flood Risk Management”*, Klijn & Schweckendiek (ed.), 2012, pp. 327–336. doi:10.1201/b13715-47
11. Pyayt A. L., Mokhov I. I., Lang B., Krzhizhanovskaya V. V., Meijer R. J. Machine Learning Methods for Environmental Monitoring and Flood Protection. *World Academy of Science, Engineering and Technology*, 2011, vol. 5, pp. 118–123.
12. Pyayt A. L., Mokhov I. I., Kozionov A. P., Kuserbaeva V. T., Lang B., Krzhizhanovskaya V. V., Meijer R. J. Data-Driven Modelling for Flood Defence Structure Analysis. *Comprehensive Flood Risk Management*, Klijn & Schweckendiek (ed.), 2013, pp. 301–306.
13. Pyayt A. L., Shevchenko D. V., Kozionov A. P., Mokhov I. I., Lang B., Krzhizhanovskaya V. V., Sloot P. M. A. Combining Data-Driven Methods with Finite Element Analysis for Flood Early Warning Systems. *Intern. Conf. on Computational Science, ICCS 2015 “Computational Science at the Gates of Nature”*, 2015, no. 51, pp. 2347–2356. doi:10.1016/j.procs.2015.05.404

14. Kozionov A. P., Pyayt A. L., Mokhov I. I., Ivanov Y. P. Wavelet Transform and One-Class Classification for Dike Health Monitoring. *Informatsionno-upravliaiushchie sistemy* [Information and Control Systems], 2014, no. 4(71), pp. 24–31 (In Russian).
15. Kozionov A. P., Pyayt A. L., Mokhov I. I., Ivanov Y. P. Research on Gap-Filling Algorithms For Dike Health Monitoring Systems. *Nauchno-tehnicheskie vedomosti SPbGPU. Informatika. Telekommunikatsii. Upravlenie*, 2015, no. 2–3, pp. 217–222 (In Russian). doi:10.5862/JCSTCS/8
16. Lang B., Poppe T., Minin A., Mokhov I., Kuperin Y., Mekler A., Liapakina I. Neural Clouds for Monitoring of Complex Systems. *Optical Memory and Neural Networks*, 2008, vol. 3, no. 17, pp. 183–192. doi:10.3103/S1060992X08030016
17. Bishop C. *Pattern Recognition and Machine Learning*. New York, Springer, 2006. 738 p.
18. Box G., Jenkins G. *Time Series Analysis: Forecasting and Control*. San Francisco, Holden-Day, 1970. 573 p.
19. Akaike H. A New Look at the Statistical Model Identification. *IEEE Transactions on Automatic Control*, 1974, no. 19(6), pp. 716–723. doi:10.1109/TAC.1974.1100705
20. *Alert Solutions*. (2015). Available at: <http://www.alertsolutions.nl/> (accessed 01 August 2015).

Уважаемые авторы!

При подготовке рукописей статей необходимо руководствоваться следующими рекомендациями.

Статьи должны содержать изложение новых научных результатов. Название статьи должно быть кратким, но информативным. В названии недопустимо использование сокращений, кроме самых общепринятых (РАН, РФ, САПР и т. п.).

Объем статьи (текст, таблицы, иллюстрации и библиография) не должен превышать эквивалента в 20 страниц, напечатанных на бумаге формата А4 на одной стороне через 1,5 интервала Word шрифтом Times New Roman размером 13, поля не менее двух сантиметров.

Обязательными элементами оформления статьи являются: индекс УДК, заглавие, инициалы и фамилия автора (авторов), ученая степень, звание (при отсутствии — должность), полное название организации, аннотация и ключевые слова на русском и английском языках, электронные адреса авторов, которые по требованию ВАК должны быть опубликованы на страницах журнала. При написании аннотации не используйте аббревиатур и не делайте ссылок на источники в списке литературы.

Статьи авторов, не имеющих ученой степени, рекомендуется публиковать в соавторстве с научным руководителем, наличие подписи научного руководителя на рукописи обязательно; в случае самостоятельной публикации обязательно предоставляйте заверенную по месту работы рекомендацию научного руководителя с указанием его фамилии, имени, отчества, места работы, должности, ученого звания, ученой степени — эта информация будет опубликована в ссылке на первой странице.

Формулы набирайте в Word, не используя формульный редактор (Mathtype или Equation), при необходимости можно использовать формульный редактор; для набора одной формулы не используйте два редактора; при наборе формул в формульном редакторе знаки препинания, ограничивающие формулу, набирайте вместе с формулой; для установки размера шрифта никогда не пользуйтесь вкладкой Other..., используйте заводские установки редактора, не подгоняйте размер символов в формулах под размер шрифта в тексте статьи, не растягивайте и не сжимайте мышью формулы, вставленные в текст; в формулах не отделяйте пробелами знаки: + = -.

Для набора формул в Word никогда не используйте Конструктор (на верхней панели: «Работа с формулами» — «Конструктор»), так как этот ресурс предназначен только для внутреннего использования в Word и не поддерживается программами, предназначенными для изготовления оригинал-макета журнала.

При наборе символов в тексте помните, что символы, обозначаемые латинскими буквами, набираются светлым курсивом, русскими и греческими — светлым прямым, векторы и матрицы — прямым полужирным шрифтом.

Иллюстрации в текст не завертываются и предоставляются отдельными исходными файлами, поддающимися редактированию:

— рисунки, графики, диаграммы, блок-схемы предоставляйте в виде отдельных исходных файлов, поддающихся редактированию, используя векторные программы: Visio 4, 5, 2002–2003 (*.vsd); Coreldraw (*.cdr); Excel (*.xls); Word (*.doc); AdobeIllustrator (*.ai); AutoCad (*.dxf); Matlab (*.ps, *.pdf или экспорт в формат *.ai);

— если редактор, в котором Вы изготавливаете рисунок, не позволяет сохранить в векторном формате, используйте функцию экспорта (только по отношению к исходному рисунку), например, в формат *.ai, *.esp, *.wmf, *.emf, *.svg;

— фото и растровые — в формате *.tif, *.png с максимальным разрешением (не менее 300 pixels/inch).

Наличие подрисовочных подписей обязательно (желательно не повторяющих дословно комментарии к рисункам в тексте статьи).

В редакцию предоставляются:

— сведения об авторе (фамилия, имя, отчество, место работы, должность, ученое звание, учебное заведение и год его окончания, ученая степень и год защиты диссертации, область научных интересов, количество научных публикаций, домашний и служебный адреса и телефоны, e-mail), фото авторов: анфас, в темной одежде на белом фоне, должны быть видны плечи и грудь, высокая степень четкости изображения без теней и отблесков на лице, фото можно представить в электронном виде в формате *.tif, *.png с максимальным разрешением — не менее 300 pixels/inch при минимальном размере фото 40×55 мм;

— экспертное заключение.

Список литературы составляется по порядку ссылок в тексте и оформляется следующим образом:

— для книг и сборников — фамилия и инициалы авторов, полное название книги (сборника), город, издательство, год, общее количество страниц;

— для журнальных статей — фамилия и инициалы авторов, полное название статьи, название журнала, год издания, номер журнала, номера страниц;

— ссылки на иностранную литературу следует давать на языке оригинала без сокращений;

— при использовании web-материалов указывайте адрес сайта и дату обращения.

Список литературы оформляйте двумя отдельными блоками по образцам lit.dot на сайте журнала (<http://i-us.ru/paperrules>) по разным стандартам: Литература — СИБИД РФ, References — один из мировых стандартов.

Более подробно правила подготовки текста с образцами изложены на нашем сайте в разделе «Оформление статей».

Контакты

Куда: 190000, Санкт-Петербург,
Б. Морская ул., д. 67, ГУАП, РИЦ

Кому: Редакция журнала «Информационно-управляющие системы»

Тел.: (812) 494-70-02

Эл. почта: ius.spb@gmail.com

Сайт: www.i-us.ru