

**А. С. Феоктистов<sup>1,2</sup>, Е. С. Нежевенко<sup>2</sup>**

<sup>1</sup> *Новосибирский государственный университет  
ул. Пирогова, 2, Новосибирск, 630090, Россия*

<sup>2</sup> *Институт автоматизации и электрометрии СО РАН  
пр. Акад. Коптюга, 1, Новосибирск, 630090, Россия*

*feoktistov.artem@gmail.com, nejevenko@iae.nsk.su*

## **ОПЕРАТИВНОЕ ПРОГНОЗИРОВАНИЕ ПРОСТРАНСТВЕННО РАСПРЕДЕЛЕННЫХ ДИНАМИЧЕСКИХ ПРОЦЕССОВ НА ПОВЕРХНОСТИ ЗЕМЛИ НА ОСНОВЕ УСВОЕНИЯ ДАННЫХ**

Предложен метод моделирования динамических процессов на поверхности Земли, таких как пожары, наводнения, сели, разливы нефти, в условиях априорной неопределенности. Данный метод основан на получении и усвоении данных моделью в ходе развития процесса. Усвоение данных обеспечивается использованием рекуррентной нейронной сети и калмановской фильтрации. Описан процесс обучения нейронной сети и предложен метод ускорения обучения нейронной сети путем использования фильтра Калмана. Проанализирована эффективность предложенного метода.

*Ключевые слова:* компьютерное моделирование, лесной пожар, рекуррентная нейронная сеть, усвоение данных, обучение, фильтр Калмана.

### **Введение**

Прогнозирование развития пространственно распределенных динамических процессов на поверхности Земли относится к числу важнейших задач, поскольку именно эти процессы характеризуют как природные, так и техногенные катастрофы (пожары, наводнения, сели, цунами, разливы нефтепродуктов на водной поверхности), которые можно считать одной из основных проблем человечества. Такое прогнозирование имеет огромное значение, поскольку ресурсы для устранения последствий этих процессов, как правило, ограничены и должны быть использованы с максимальной эффективностью. В то же время прогноз должен быть основан на информации, получаемой с места развития процесса, определяющей его протекание (температура, влажность, направление ветра – пожары; рельеф дна – цунами; направление течений – разливы нефти), а получить ее чрезвычайно трудно, поскольку при протекании процесса часто становятся недоступными средства получения информации (датчики), т. е. прогноз должен осуществляться при большой априорной неопределенности. В то же время предполагается, что изображения самого процесса или результата его действия могут быть получены с помощью средств наблюдения: аэрокосмических, радиолокационных либо другими способами.

### **Прогнозирование динамических процессов**

В цикле работ [1–3] была разработана методика моделирования лесных пожаров, основанная на процессе усвоения данных. Перспективным решением поставленной задачи явля-

*Феоктистов А. С., Нежевенко Е. С. Оперативное прогнозирование пространственно распределенных динамических процессов на поверхности земли на основе усвоения данных // Вестн. Новосиб. гос. ун-та. Серия: Информационные технологии. 2015. Т. 13, вып. 2. С. 103–115.*

ется использование нейронных сетей. Основным преимуществом такого представления выступает возможность осуществлять процедуры усвоения данных путем хорошо проработанного обучения нейронной сети, где в качестве обучающей выборки используются результаты наблюдения процессов (оптического, радиолокационного и др.). Данная методика может быть легко расширена и на другие классы динамических процессов. Ниже изложены ключевые моменты методики.

Предпосылкой использования нейронной сети для моделирования динамических процессов является то, что подавляющее число последних может быть описано в терминах распространения волнового фронта. А оно, как известно, предполагает использование принципа Гюйгенса. В соответствии с ним каждая точка фронта (поверхности, достигнутой волной) является вторичным (т. е. новым) источником сферических волн. Создадим нейронную сеть, поместив в эти точки нейроны (конечно, с соответствующим прореживанием). Роль волн здесь играют сигналы, распространяющиеся от каждого возбужденного нейрона к принимающим нейронам через синаптические связи. Удобно распространение процесса моделировать в полярной системе координат, причем нейроны располагаются на радиусах системы.

В реальных процессах роль синаптических связей нейронов играют каналы передачи энергии или вещества (в случае пожаров – каналы теплопередачи), а синаптические коэффициенты определяются параметрами среды. Сигналы от возбужденных нейронов суммируются возбуждаемыми, и если порог активации превышен, нейрон переходит в состояние возбуждения. В активном состоянии нейрон находится конечное время, после чего навсегда переходит в неактивное состояние. Рабочая область в окрестности фронта развития процесса, состоящая из возбужденных и возбуждаемых нейронов, перемещается по радиусам, возбуждаемые нейроны замещаются возбужденными и таким образом реализуется рекуррентная нейронная сеть. На рис. 1 черным показаны нейроны в состоянии возбуждения, белым – принимающие сигнал. Положение нейрона  $(i, j)$  относительно центра выражается в полярных координатах следующим образом:  $r = \Delta r * j$ ,  $\varphi = \Delta \varphi * i$ , где  $\Delta r$  и  $\Delta \varphi$  – шаги сетки по радиусу и по углу соответственно;  $d_i$  – параметр индикатрисы нейрона, отражающий протяженность влияния на соседние нейроны.




Рис. 1. Распространение процесса в виде нейронной сети



Рис. 2. Процесс обучения нейронной сети: *a* – предсказание развития процесса на текущем шаге; *б* – сравнение с реальным развитием и обучение нейронной сети; *в* – предсказание после обучения (практически сходится с реальным развитием процесса)

На каждом шаге после расчета состояния системы производится коррекция синаптических коэффициентов для нейронов, находящихся в рабочей области. Коррекция осуществляется за счет несвязного расширенного фильтра Калмана, обеспечивающего ускоренную адаптацию. Вектор состояний определяется набором исходных параметров среды, а учет наблюдений ведется сравнением рассчитанного состояния с действительным развитием процесса. Разница между их фронтами минимизируется путем коррекции вектора состояний. На основании изложенных принципов было создано программное обеспечение для моделирования развития лесных пожаров [3]. Эффективность моделирования доказана путем введения неопределенности в исходный набор параметров с последующим адаптивным восстановлением вектора состояний.

Как видно из описания методики прогнозирования, за основу берется разбиение области распространения процесса на ячейки (клетки), каждая из которых может находиться в одном из нескольких состояний. Как правило, для каждого процесса существует от одного до нескольких основных параметров, характеризующих состояние определенной клетки. Так, для пожара это накопленная энергия, необходимая для воспламенения, если энергии недостаточно, клетка находится в состоянии предзагорания, если превышено пороговое значение – клетка переходит в состояние горения. Для наводнений это уровень / объем воды в клетке, для разливов нефти – наличие нефтяного загрязнения, для цунами – высота воды над уровнем моря.

### Индикатриса направленности

В основе всех подобных процессов лежит передача, распространение «энергии» ячейки на все другие ячейки, причем передача энергии характеризуется определенным законом. Назовем характеристику передачи энергии от ячейки *индикатрисой направленности*. В общем случае индикатрисой направленности является поле значений, характеризующих величину передаваемой энергии от ячейки на любую другую ячейку. Варианты распространения пожара и соответствующей ему индикатрисы направленности отражены на рис. 3.

Ключевой особенностью индикатрисы является то, что она может быть представлена в определенном приближении в аналитическом виде. Так, в случае пожара индикатриса хорошо поддается описанию с помощью эллипса. Таким образом, для приближенного описания передачи требуется всего три параметра (угол поворота эллипса и два радиуса). В случае других процессов так же не сложно подобрать законы описывающие индикатрису направленности.

### Нейронная сеть

С другой стороны, процесс передачи энергии от ячейки к ячейке можно рассматривать как процесс передачи сигнала от одного нейрона к другому. Тем самым получаем пространственно распределенную нейронную сеть, где каждый нейрон связан с каждым другим синаптическими связями, в которых сигналы умножаются на синаптические коэффициенты.

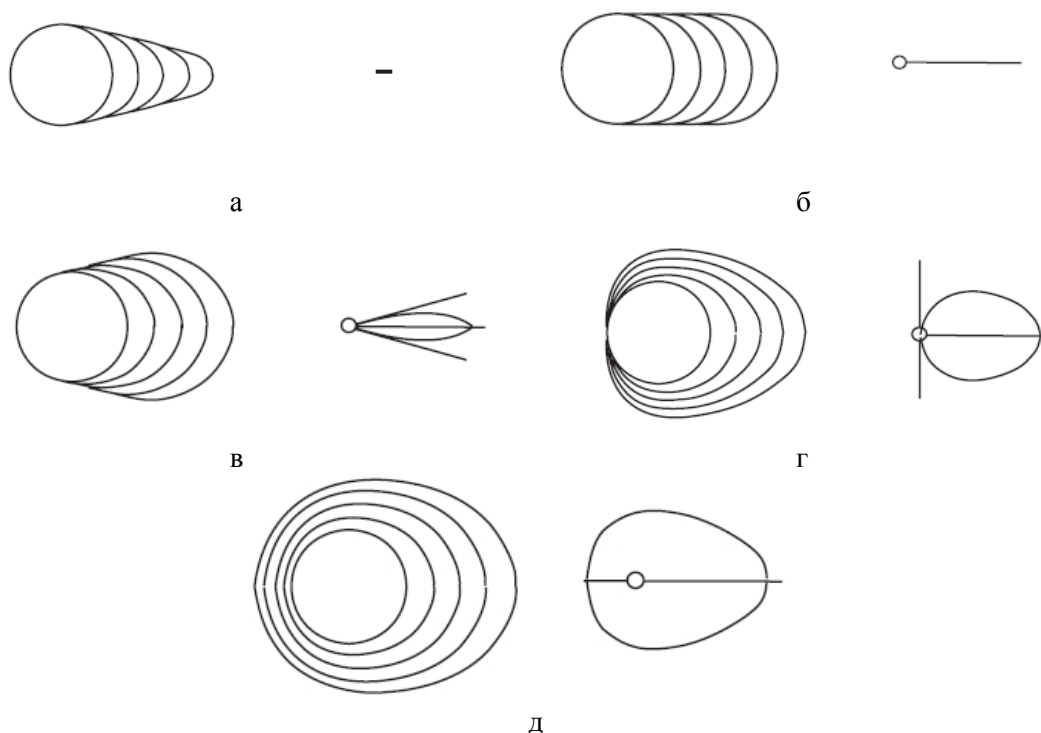


Рис. 3. Варианты распространения пожара и индикатрис




Рис. 4. Процесс замещения нейронов во фронте процесса: *а* – часть фронта нейронной сети; *б* – разбиение на двухслойную сеть; *в* – процесс замены нейронов в двухслойной сети

Такая сеть очень нагружена синаптическими связями, для упрощения сети предлагается брать за основу только нейроны, находящиеся во фронте процесса, т. е. непосредственно участвующие в передаче и приеме сигнала в данный момент времени. Таким образом, образуется двухслойная сеть нейронов, находящаяся на фронте процесса (рис. 4). Один слой передает возбуждение, второй принимает. Если нейрон перестает принимать или передавать сигнал, то он автоматически исключается из этой нейронной сети. Важным моментом является добавление нового нейрона в нейронную сеть. Так как каждый нейрон соответствует ячейке среды, то его синаптические коэффициенты могут быть рассчитаны исходя из параметров ячейки. Однако основной проблемой выступает неточность априорных данных о процессе, в том числе и параметров каждой отдельной ячейки. Заметим, что значения параметров меняются незначительно между соседними ячейками. Так как на каждом шаге произ-

водится обучение нейронной сети, предлагается использовать следующую формулу для вычисления параметров нового нейрона:

$$P_n = k * P_{avr} + (k - 1) * P_{env}, \quad (1)$$

где  $P_n$  – параметр нейрона,  $P_{avr}$  – средний параметр соседних нейронов,  $P_{env}$  – параметр среды, а  $k$  – коэффициент доверия обучения нейронной сети по отношению к априорным данным.

### Усвоение данных

Как уже было сказано, основной проблемой прогнозирования является неточность априорных данных, при этом наиболее актуальные данные могут быть получены в ходе развития процесса. Коррекция расчетов математической модели данными наблюдений представляет собой одну из наиболее актуальных и интересных задач в современной математической геофизике. В мировой практике такие задачи получили название задач ассимиляции (усвоения) и им посвящена обширная литература. В целом методы ассимиляции можно разделить на две большие группы. Одна группа методов основана на вариационных принципах (поиск минимума некоторого функционала, описывающего «близость» модельного решения и данных измерений в некоторой заданной метрике), получивших название в литературе как вариационный метод решения задач усвоения. Другой подход – фильтрация Калмана – основан на статистической теории оценивания и фильтрации процессов на фоне «шума» с известными статистическими свойствами. В работах [4; 5] проведен обзор сравнения вариационных методов и Калмановской фильтрации. Кроме этого, показано, что фильтр Калмана может быть получен из формул вариационного метода путем замыкания некоторых степеней свободы системы самих на себя.

В нашей работе для усвоения данных используется обучение нейронной сети, которая в свою очередь является отражением развития процесса в рамках математической модели. На каждом шаге прогнозирования предсказанный фронт процесса сравнивается с наблюдаемым, после этого устраняется невязка путем обучения нейронной сети. Наиболее простым способом обучения является метод градиентного спуска. При этом значения параметров новых нейронов корректируются по формуле (1), таким образом, обеспечивается процесс усвоения данных.

Проблемами обучения нейронной сети являются отсутствие учета модели процесса и скорость обучения. В отличие от нейронной сети предсказания фильтра Калмана [6] как раз основаны на модели процесса и учитывают возможные шумовые колебания процесса. В работе [3] была предложена вариация фильтра Калмана для ускорения обучения нейронной сети в случае пожаров. Ее достаточно легко переопределить для всех пространственно распределенных динамических процессов.

### Фильтр Калмана

Начнем объяснение с описания развития динамического процесса в рамках пространства состояний. Очень важен вопрос о том, что взять в качестве компонентов вектора состояния системы. Можно в качестве таковых использовать параметры внешней среды, определяющие движение фронта. Другой подход – взять в качестве компонентов вектора состояния параметры индикатрисы направленности. Как уже говорилось, она может быть представлена аналитической формулой. Так, для пожара он определяется тремя параметрами: размером большой полуоси  $z_0$ , эксцентриситетом  $e$  и наклоном большой полуоси  $\varphi_0$  [7]. Мы будем использовать второй вариант, поскольку он лучше характеризует нейросеть: зная параметры индикатрис, можно сразу же построить синаптические связи. Будем считать, что для  $i$ -го луча и  $k$ -го этапа для всех  $n_{ai}$  нейронов луча вектор состояния будет одинаков. Тогда в глобальной модели сети размерность вектора состояния  $W(k)$  будет  $z = n_{i*s}$ , где  $s$  – число параметров. Размерность вектора измерения  $d(k)$  –  $n_i$ , по числу лучей. Перемещение фронта описывается выражением

$$d_i(k) = C(W(k), \beta(k)) + \beta(k), \quad (2)$$

где  $\beta(k)$  – вектор погрешности измерений,  $C$  – нелинейность при измерении. Предполагается, что погрешность измерений  $\beta(k)$  имеет нулевое среднее значение и является процессом многомерного белого шума с диагональной матрицей ковариации:

$$E[\beta(k)\beta^T(m)] = \begin{cases} R(k), k = m \\ 0, k \neq m \end{cases}$$

Обучение такой нейронной сети будет состоять в корректировке  $z$  параметров, цель обучения – минимизация среднего квадрата отклонения  $\sum_{i=1}^p (d_i - d_i^*)^2$ . Эта корректировка, в свою очередь, приведет к изменению синаптических коэффициентов, которые зависят от параметров. Поскольку связь вектора параметров и вектора наблюдения нелинейная, эта модель соответствует глобальному расширенному фильтру Калмана. Чтобы применить теорию фильтра Калмана, линеаризуем уравнение (2), представив его в виде

$$d_i(k) = CW(k) + \beta(k), \quad (3)$$

где  $C$  – матрица измерения линеаризованной модели размерности  $z$  находится как

$$C = \begin{pmatrix} \frac{\partial c_1}{\partial w_1} & \frac{\partial c_1}{\partial w_2} & \dots & \frac{\partial c_1}{\partial w_z} \\ \frac{\partial c_2}{\partial w_1} & \frac{\partial c_2}{\partial w_2} & \dots & \frac{\partial c_2}{\partial w_z} \\ \dots & \dots & \dots & \dots \\ \frac{\partial c_p}{\partial w_1} & \frac{\partial c_p}{\partial w_2} & \dots & \frac{\partial c_p}{\partial w_z} \end{pmatrix}. \quad (4)$$

В этом случае требуются операции с матрицами большой размерности, поэтому перейдем к модели несвязного расширенного фильтра Калмана. В соответствии с этой моделью выделим  $n_i$  (по числу лучей) групп нейронов. В каждую  $i$ -ю группу входит:  $n_{ai}$  входных нейронов и  $n_{pi}$  нейронов скрытого слоя, связанных с входными нейронами синаптическими связями, которые определяются  $z_i = s$  параметрами вектора состояния. Основным отличием предлагаемой модели от известных [8] является то, что в ней одни и те же нейроны входят в несколько соседних групп, т. е. группа как бы перемещается по скрытому слою. Общее количество выходных нейронов, соответствующее нейронам скрытого слоя,  $p = \sum_{i=1}^{n_i} n_{pi}$ .

Итак, мы подготовили все для применения алгоритма фильтрации Калмана. В частности, для линеаризованной динамической модели

$$\Gamma(k) = \left[ \sum_{i=1}^{n_i} C_i(k) K_i(k \| k-1) C_i^T(k) + R(k) \right]^{-1}; \quad (5)$$

$$G_i(k) = K_i(k \| k-1) C_i^T(k) \Gamma(k); \quad (6)$$

$$\alpha(k) = d^*(k) - d(k \| k-1); \quad (7)$$

$$\hat{w}_i(k+1 \| k) = \hat{w}_i(k \| k-1) + G_i(k) \alpha(kn); \quad (8)$$

$$K_i(k+1 \| k) = K_i(k \| k-1) - G_i(k) C_i(k) K_i(k \| k-1). \quad (9)$$

Здесь  $C_i$  – составная часть матрицы  $C$  для  $i$ -го блока;

$\Gamma(k)$  – матрица размерности  $p \times p$ , представляющая собой глобальный коэффициент передачи для всей сети;

$G_i(k)$  – матрица размерности  $s \times p$ , обозначающая коэффициент усиления Калмана для  $i$ -й группы составляющих вектора состояния;

$\alpha(k)$  – вектор размерностью  $n_l$  – невязка, определяемая как разность между желаемым откликом  $d(k)$  линеаризованной системы и его оценкой  $d(k \| k-1)$ , основанной на входных данных, доступных в момент времени  $k-1$ , а эта оценка  $d(k \| k-1) = C(k) \hat{w}(k \| k-1)$ ;

$\hat{w}(k \| k-1)$  – вектор размерностью  $s \times I$ , являющийся оценкой вектора состояния  $\hat{w}_i(k)$  для группы  $i$  в момент времени  $k$ , при наличии наблюдаемых данных вплоть до момента времени  $k-1$ ;

$K_i(k \| k-1)$  – матрица размерностью  $s \times s$ , являющаяся матрицей ковариации ошибок составляющих вектора состояния для  $i$ -й группы. Суммирование, выполняемое при вычислении глобального коэффициента передачи  $\Gamma(k)$ , учитывает несвязную природу расширенного фильтра Калмана:

$$K_i(k \| k-1) = E[\varepsilon(k \| k-1)\varepsilon^T(k \| k-1)],$$

где ошибка вектора состояния  $\varepsilon(k \| k-1)$  определяется как

$$\varepsilon(k \| k-1) = w(k) - \hat{w}_i(k \| k-1).$$

Как показано в [4], в уравнение (9) целесообразно добавить искусственный шум  $\omega_i(k)$  – многомерный белый шум с диагональной ковариационной матрицей  $Q_i(k)$ , что снижает вероятность попадания в локальный минимум при обучении. Тогда выражение (9) преобразуется так:

$$K_i(k+1 \| k) = K_i(k \| k-1) - G_i(k)C_i(k)K_i(k \| k-1) + Q_i(k). \quad (10)$$

С учетом этого полная процедура расщепленного расширенного фильтра Калмана выглядит следующим образом.

*Инициализация:*

- параметры индикатрис теплопередачи  $w(\rho)_0$  задаются согласно имеющимся априорным данным (параметрами ветра, склона, горючей среды);
- в ковариационной матрице  $Q_i(k)$ , характеризующей искусственно введенный шум  $\omega_i(k)$ , диагональные элементы устанавливаются в диапазоне от  $10^{-3}$  до  $10^{-2}$ ;
- начальное значение ковариационной матрицы ошибок  $K_i(k \| k-1)$  полагаем  $K_i(1 \| 0) = \delta^{-1}I$ , где  $\delta$  – малое положительное число.

*Вычисления:* для  $k = 1, 2, 3, \dots$  последовательно вычисляем рекурсивные соотношения (5)–(9).

Еще раз определим все переменные:

$c_i(n)$  вычисляется в соответствии с (3), (4):  $c_i = \frac{\Delta c_i}{\Delta w_i}$ , т. е. путем придания малых изменений  $w(\rho)$ .

$K_i(1 \| 0)$  определяется в соответствии с п. 3 «инициализация», а последующие значения  $K$  получаются рекуррентно в соответствии с (10);

$R(k)$  получаем исходя из ошибки измерения положения фронта пожара;

$d_i(k)$  – перемещение фронта пожара, измеряемое системой наблюдения;

$d_i(k \| k-1) = C(k)\hat{w}_i(k \| k-1)$ , где  $\hat{w}_i(1 \| 0)$  – начальное значение вектора состояния определяется априорными сведениями об индикатрисе теплопередачи, зависящими от направления и силы ветра, влажности и т. д. Последующие значения вычисляются рекуррентно, в соответствии с (8).

В связи с тем, что перемещение фронта  $d_i(k)$  зависит не только от индикатрис нейронов, находящихся на  $i$ -м луче, но и от соседних нейронов, индикатрисы которых пересекают  $i$ -й луч, может понадобиться несколько проходов по всем лучам. Критерием окончания итераций на  $k$ -м цикле является достижение неравенства  $\alpha(k) = d^*(k) - \hat{d}(k \| k-1) < \delta$ , где  $\delta$  – наперед заданный вектор.

## Результаты

В ходе исследования разработанный подход был применен к некоторым представителям класса динамических процессов, происходящих на земной поверхности. Основное внимание было уделено пожарам, на которых данный подход показал хорошие результаты [9]. Кроме этого, было исследовано моделирование наводнений, разливов нефти и цунами. Наиболее важным шагом в построении модели является выбор оптимальной математической мо-

дели для построения индикатрисы направленности, после чего все сводится к общему алгоритму действий.


### Пожары

В качестве базовой математической модели использовалась модель Ротермела, которая дает качественный прогноз в условиях точных входных данных. Результаты моделирования пожара на реальной местности с различными направлениями ветра представлены на рис. 5, результаты моделирования пожара на реальной местности со значительными перепадами высот – на рис. 6.

### Наводнения

В качестве базовой математической модели при моделировании наводнений использовалась улучшенная формула Маннинга [10]. Поток воды между двумя клетками может быть рассчитан по формуле

$$Q_{i,j} = \frac{bh_m^{5/3}}{n} \left( \frac{H_i - H_j}{\Delta x} \right)^{1/2},$$



Условные обозначения для рис. 5 и 6:

- – лес, ■ – травяное покрытие, ■ – земля и сгоревшие участки
- – горящие участки, □ – нагревающиеся участки

Рис. 5. Развитие пожара на реальной местности:  
*а* – скорость ветра 1 м/с, направление юго-западное; *б* – скорость ветра 0 м/с;  
*в* – скорость ветра 3 м/с, направление северо-восточное






Рис. 6. Развитие пожара на реальной местности, ветер 0 м/с, перепад высот с севера на юг 30 м, слева расположена дорога

где  $H_i$  и  $H_j$  – высота воды в клетках;  $\Delta x$  – расстояние между ячейками;  $b$  – ширина линии контакта;  $n$  – коэффициент шероховатости Маннинга;  $h_m$  – арифметическое среднее между высотами двух ячеек. Зная поток воды между двумя клетками, индикатрису направленности можно получить из общего потока воды из ячейки:

$$Q(V_i) = \frac{\Delta V_i}{\Delta t} = \sum_{j=1}^m Q_{i,j}.$$

Изменение объема ячейки за промежуток времени  $\Delta t$  :

$$\Delta V_{t+\Delta t} = \Delta t * Q(V_i) + O(Q^2).$$

Результаты моделирования наводнения отражены на рис. 7.


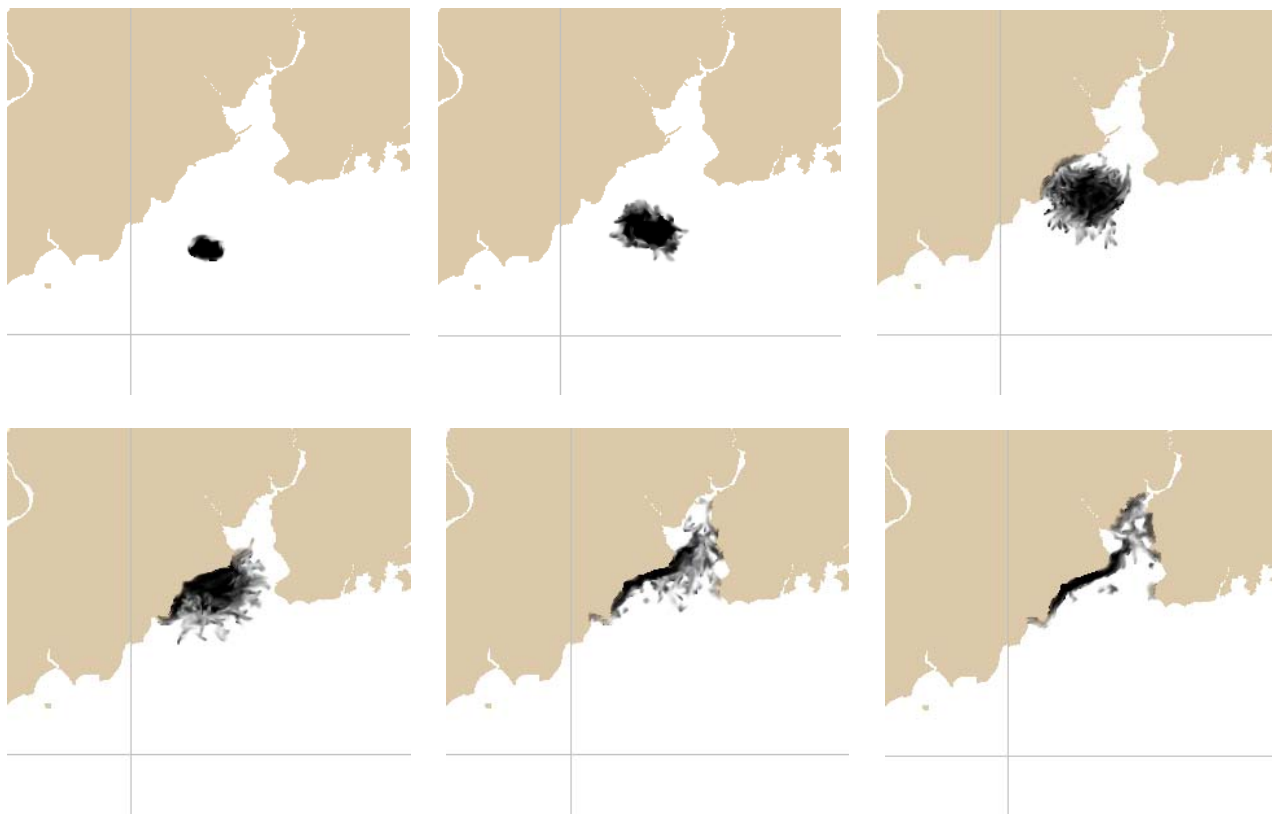


Рис. 7. Затопление рельефной местности



*Рис. 8.* Растекание нефтяного пятна

## Разливы нефти

Метод моделирования основан на расчете количества нефти в пятне, остающейся по мере распространения его в море. В качестве математической модели использована модель переноса вещества с учетом его свойств и характера взаимодействия со средой. Для расчета процесса распространения вещества необходимы знания также о гидрофизических полях самой среды. Предлагаемая ниже модель универсальна и позволяет описывать не только нефтяное загрязнение, но и любую другую примесь, если известны законы ее взаимодействия со средой. К ним относятся начальное формирование слика под воздействием гравитационных сил, адвективный перенос, турбулентное перемешивание, испарение, эмульгирование, диспергирование, фотоокисление, растворение, биодеградация и оседание, подробное описание которых представлены в [11]. Агрегация всех описанных воздействий определяет поле скоростей распространения нефти в каждый шаг времени, а значит, и поле индикатрис направленности для процесса. Ниже приведены некоторые формулы модели. Гравитационное растекание:

$$\frac{dS}{dt} = K_1 S^{0,33} (V / S)^{1,33},$$

где  $S$  – площадь пятна;  $K_1$  – размерный коэффициент, равный 150/с;  $t$  – время.

Адвекция – движение пятна нефти как единого целого происходит под воздействием течения, компоненты вектора  $V_i$  которого определяются совокупностью ряда составляющих:

$$V_i^{wid} + V_i^{wad} + V_i^d + V_i^c,$$

где  $V_i$  соответствуют ветровому и волновому дрейфу пятна;  $V_i^d$  – средняя скорость дрейфового течения,  $V_i^c$  обозначает среднюю климатическую составляющую скорости течения. Дрейф пятна под непосредственным воздействием ветра и волн учитывался на основе соотношения  $V_i^{wid} + V_i^{wad}$ .

Далее переходим к стандартной работе алгоритма. На рис. 8 представлены результаты моделирования растекания нефтяного пятна, скорость ветра 4 м/с, направление северное, растекание происходит в течение одного дня.

## Заключение

В работе представлен метод моделирования динамических процессов на поверхности земли в условиях априорной неопределенности. Ключевой особенностью метода является возможность усвоения данных, полученных в ходе развития процесса (наблюдение за процессом: аэро- и космическая съемка и др.). Усвоение данных обеспечивается обучением рекуррентной нейронной сети, причем обучение происходит путем сравнения прогноза распространения процесса с помощью компьютерного моделирования и реального наблюдения области распространения. Усвоение данных позволяет существенно снизить влияние на результат моделирования априорной неопределенности, практически всегда присущей динамическим процессам на поверхности Земли, связанной с плохо предсказуемыми изменениями внешних условий. Поскольку данный метод предполагается использовать в оперативной обстановке, для ускорения процесса усвоения данных, реализуемого путем обучения нейронной сети, предложено использовать фильтр Калмана, который в отличие от обычного процесса обучения учитывает уравнения, определяющие функционирование модели, а также возможные ошибки системы наблюдения за процессом.

Предложенный метод опробован на нескольких видах динамических процессов, таких как лесные пожары, наводнения и др., и для каждого из процессов показал хорошие результаты. Большим плюсом является то, что данный метод может быть использован совместно с любой математической моделью, описывающей процесс, и служит для ее уточнения путем усвоения данных, что практически во всех случаях повышает точность моделирования.

### Список литературы

1. Нежевенко Е. С., Козик В. И., Феоктистов А. С. Адаптивное прогнозирование развития динамических процессов на поверхности Земли с использованием рекуррентных нейронных сетей // Математические и информационные технологии, MIT-2011: Сб. тр. Междунар. конф. Белград, 2012. С. 226–231.
2. Козик В. И., Нежевенко Е. С., Феоктистов А. С. Нейросетевой метод прогнозирования развития динамических процессов на поверхности Земли // Распределенные информационные и вычислительные ресурсы: Тез. XIV Рос. конф. с международным участием. Новосибирск, 2012.
3. Kozik V. I., Nezhevenko E. S., Feoktistov A. S. Adaptive prediction of forest fire behavior on the basis of recurrent neural networks // Optoelectronics, Instrumentation and Data Processing. 2013. Vol. 49. Iss. 3. P. 250–259.
4. Ипатова В. М., Шутяев В. П. Алгоритмы и задачи ассимиляции данных для моделей динамики атмосферы и океана. Долгопрудный, 2013.
5. Пененко В. В. Вариационное усвоение данных в реальном времени // Вычислительные технологии. 2005. Т. 10, ч. 1.
6. Haykin S. Kalman filtering and neural networks. Awiley: Intrescience publication, 2001.
7. Дорпер Г. А. Динамика лесных пожаров. Новосибирск: Изд-во СО РАН, 2008.
8. Haykin S. Neural networks. N. Y.: Prentice Hall, 1999.
9. Kozik V. I., Nezhevenko E. S., Feoktistov A. S. Studying the Method of Adaptive Prediction of Forest Fire Evolution on the Basis of Recurrent Neural Networks // Optoelectronics, Instrumentation and Data Processing. 2014. Vol. 50. Iss. 4. P. 1–7.
10. Dottori F., Todini E. A 2d flood inundation model based on cellular automata approach // XVIII International Conference on Water Resources CMWR / J. Carrera (ed.). Barcelona 2010.
11. Коротенко К. А., Мамедов Р. М. Моделирование процессов распространения нефтяных пятен в прибрежной зоне Каспийского моря // Океанология. 2001. Т. 41 (6). С. 34–45.

Материал поступил в редколлегию 05.12.2014

**A. S. Feoktistov<sup>1,2</sup>, E. S. Nezhevenko<sup>2</sup>**

<sup>1</sup>Novosibirsk State University  
2 Pirogov Str., Novosibirsk, 630090, Russian Federation

<sup>2</sup>Institute of Automation and Electrometry SB RAS  
1 Acad. Koptug Ave., Novosibirsk, 630090, Russian Federation

feoktistov.artem@gmail.com, nejevenko@iae.nsk.su

### FORECASTING OF DYNAMIC PROCESSES ON THE EARTH SURFACE BASED ON DATA ASSIMILATION

A method of modeling a dynamic process on the Earth surface, such as wildfires, floods, mudslides, oil spills, in the conditions of a priori uncertainty is proposed. This method is based on the data assimilation approach. Data assimilation is realized using recurrent neural networks and Kalman filtering. The training process of the neural network is described and also we propose a method for accelerating neural network training through the using of a Kalman filter. The efficiency of its application is analyzed.

*Keywords:* computer simulation, wildfire, recurrent neural network, data assimilation, Kalman filter.

### References

1. Kozik V. I., Nezhevenko E. S., Feoktistov A. S. Adaptive prediction of dynamic processes on the surface of the earth using a recurrent neural networks. *International Conference «Mathematical and Informational Technologies, MIT-2011»*, 2012, p. 226–231.

2. Kozik V. I., Nezhevenko E. S., Feoktistov A. S. Neural network method for predicting the behavior of dynamic processes on the surface of the Earth. *Abstracts XIV Russian conference with international participation «Distributed information and computational resources» (DICR-2012) (Novosibirsk, Russia, 26–30 November 2012)*. Novosibirsk, 2012.
3. Kozik V. I., Nezhevenko E. S., Feoktistov A. S. Adaptive prediction of forest fire behavior on the basis of recurrent neural networks. *Optoelectronics, Instrumentation and Data Processing*, May 2013, vol. 49, iss. 3, p. 250–259.
4. Ipatova V. M., Shutyaev V. P. Algorithms and data assimilation problem for models of the dynamics of the atmosphere and ocean. *Dolgoprudny*, 2013
5. Penenko V. V. Variational data assimilation in real time. *Computational Technologies*, 2005, vol. 10, part 1.
6. Haykin S. Kalman filtering and neural networks. Awiley, Intrescience publication, 2001.
7. Dorrer G. A. The dynamics of forest fires. Novosibirsk, SB RAS, 2008.
8. Haykin S. Neural networks. N. Y., Prentice Hall, 1999.
9. Kozik V. I., Nezhevenko E. S., Feoktistov A. S. Studying the Method of Adaptive Prediction of Forest Fire Evolution on the Basis of Recurrent Neural Networks. *Optoelectronics, Instrumentation and Data Processing*, 2014, vol. 50, iss. 4, p. 1–7.
10. Dottori F., Todini E. A 2d flood inundation model based on cellular automata approach. *XVIII International Conference on Water Resources CMWR*. J. Carrera (ed.). Barcelona, 2010.
11. Korotenko K. A., Mamedov R. M. Modeling the propagation of oil spills in the coastal zone of the Caspian Sea. *Oceanology*, 2001, vol. 41 (6), p. 34–45.