

УДК 630.43 : 681.3

## АДАПТИВНОЕ ПРОГНОЗИРОВАНИЕ РАЗВИТИЯ ЛЕСНЫХ ПОЖАРОВ НА ОСНОВЕ РЕКУРРЕНТНЫХ НЕЙРОННЫХ СЕТЕЙ

В. И. Козик, Е. С. Нежевенко, А. С. Феоктистов

*Институт автоматизации и электрометрии СО РАН,  
630090, г. Новосибирск, просп. Академика Коптюга, 1  
E-mail: nejevenko@iae.nsk.su*

Предложен метод моделирования динамического процесса на поверхности Земли, например лесного пожара, с помощью рекуррентной нейронной сети. Описан процесс обучения нейронной сети, аналогичный процессу усвоения данных в ГИС-технологиях. Рассмотрен метод ускорения обучения нейронной сети путём использования калмановской фильтрации. Проанализирована эффективность её применения и определены значения параметров нейронной сети, при которых целесообразно использовать фильтр Калмана.

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

**Введение.** В работе [1] для моделирования динамических процессов на поверхности Земли предложено рассматривать последнюю как нейронную сеть, в которой возбуждение нейрона соответствует распространению процесса на определённый участок земной или водной поверхности. Такими процессами могут быть пожары, наводнения, разлив нефти и т. д. Они отличаются высокой степенью априорной неопределённости, поскольку многие параметры земной поверхности, влияющие на развитие процесса, либо изначально известны с ошибкой, либо изменяются со временем. Основным преимуществом такого представления является возможность обучения нейронной сети при распространении процесса путём использования в качестве обучающего материала результатов его наблюдения (оптического, радиолокационного и других). Априорная неопределённость обусловлена невозможностью точного установления параметров как подстилающей поверхности, на которой развивается процесс, так и атмосферных факторов, влияющих на него. Эту проблему предлагается решить путём адаптации корректирующих параметров модели, сравнивая результаты экстраполяции процесса с действительной ситуацией. Такая информация может быть получена с помощью анализа последовательности изображений, являющихся внешним проявлением процесса.

Рассмотрим метод на примере одного из наиболее характерных процессов подобного типа — лесного пожара [2]. Здесь обучение выглядит следующим образом. По результатам наблюдения пожара и имеющимся априорным данным рассчитывается прогноз на следующий этап. Результат наблюдения на этом этапе сравнивается с прогнозом и производится итерационная коррекция (обучение) модели до тех пор, пока невязка прогноза и реальности не станет меньше заданной величины.

В отличие от известных методов, которые работают только тогда, когда пространственный процесс непрерывен, предложенный метод, основанный на моделировании пожара нейронной сетью с глобальными связями, даёт возможность проводить моделирование и в тех случаях, когда процесс прерывается (так, в случае пожара в качестве элементов разрыва могут выступать овраги и реки, возникающие на пути распространения фронта

пожара). Благодаря этой особенности можно не только прогнозировать развитие процесса, но и оценивать эффективность мер устранения наносимого пожаром ущерба до их непосредственного применения (моделирование искусственно выкопанных рвов для задержки распространения пожара, уничтожение горючего материала путём встречного пожара). При реализации этой процедуры обучение, естественно, производится только до начала моделирования виртуальных препятствий. В работе [2] для моделирования распространения пожара и его прогнозирования использовались два типа различных нейронных сетей, одна из которых применялась для моделирования развития пожара, а другая — для адаптации (обучения) или коррекции его параметров для эффективного прогноза.

Целью предлагаемой работы является создание метода ускорения обучения нейронной сети и учёта возможных ошибок при наблюдении фронта с применением калмановской фильтрации.

**Модель пожара.** Для лучшего понимания дальнейшего изложения приведём некоторые сведения о модели пожара, представленные в [2]. Программная модель разработана на основе модели Ротермела [3] и учитывает следующую априорную информацию: запас сухого горючего, удельную поверхность материала (отношение площади поверхности к объёму материала), влагосодержание, эффективную теплоту воспламенения  $Q_{эфф}$ , тепловой поток  $I_R$ , отдаваемый наружу горящим материалом. Коэффициенты ветра  $\varphi_v$  и склона и  $\varphi_c$  определяют передачу теплового потока.

Вся область пожара разбивается на ячейки (в предельном случае ячейка — это пиксел изображения), каждой из которых сопоставляется нейрон. Ячейка может находиться в трёх состояниях: предзагорание (фаза 1), горение (фаза 2), всё сгорело и загореться не может (фаза 3). Этим фазам соответствует три состояния нейрона: накопление в нейроне сигналов по времени и множеству — суммарный сигнал ниже порога, нейрон не возбуждён; суммарный сигнал превышает порог, нейрон возбуждён и передаёт сигналы на соседние ячейки; латентный период — нейрон не возбуждён и возбудиться не может. При возгорании участка (возбуждении нейрона) сигнал передаётся как на соседние, так и на удалённые участки, причём роль синаптических связей играют каналы теплопередачи, а синаптические коэффициенты определяются параметрами среды: влажностью, направлением и скоростью ветра, характером склона и т. д.

Приведём описание отмеченных выше трёх фаз ячеек — нейронов.

Фаза 1. Ячейка интегрирует тепловые потоки  $I_{Ri}$  со всех ячеек, находящихся в фазе 2, индикатрисы теплопередачи которых достигают испытываемой ячейки. Ячейка ничего не излучает. Когда накопленный тепловой поток  $I_{R\Sigma}$ , определяемый характером материала и его влажностью, превысит  $Q_{эфф}$ :

$$I_{R\Sigma} = \sum_{i=1}^N I_{Ri}(1 + \varphi_c + \varphi_v) \geq Q_{эфф}, \quad (1)$$

где  $N$  — общее число ячеек, индикатрисы теплопередачи которых достигают испытываемой ячейки, происходит возгорание и ячейка переходит в фазу 2.

Фаза 2. В этом состоянии ячейка излучает тепловой поток  $I_R$  в соответствии с индикатрисой теплопередачи. Время горения ячейки задаётся параметрами Ротермела: потенциальным временем сгорания ячейки, зависящим от характера топлива; коэффициентом замедления горения по влажности; коэффициентом замедления горения по составу минерального сырья.

Фаза 3. Ячейка сгорела, ничего не воспринимает и не излучает.

Ещё раз отметим, что связи между нейронами, определяемые индикатрисой теплопередачи, глобальные, за счёт этого модель пожара может преодолевать препятствия в виде

негорючих участков (рвов, водных поверхностей и т. д.). Глобальность позволяет модели работать и в случае множественных очагов пожара (тепловые потоки, пришедшие на суммирующий нейрон от дальних нейронов, интегрируются в соответствии с (1)) [1, 2].

В представленной работе в отличие от [2], где использовался «квадратно-гнездовой» метод расположения нейронов, рассматривается радиальное расположение, что позволяет снизить расчётное время прогнозирования. Во многом это обусловлено тем, что все аналитические зависимости, реализованные в модели, были получены для радиальной системы координат и имеют в ней более простой для расчётов вид. Так, при использовании квадратно-гнездового расположения для каждого нейрона необходимо рассчитывать отдельно нормальную и радиальную составляющие скорости, чего не требуется при радиальном расположении. Чтобы избежать снижения точности прогнозирования при расширении площади пожара, предлагается вводить дополнительные лучи так, чтобы расстояние между соседними нейронами не превышало заранее заданной фиксированной величины. Таким образом, распространение пожара будем рассматривать в полярной системе координат, причём нейроны, соответствующие ячейкам, будут располагаться на радиусах системы (их угловой шаг определяется масштабом зоны действия пожара), шаг нейронов по радиусу примем равномерным. Функция активации каждого нейрона, пропорциональная индикатрисе теплопередачи ячейки, в цилиндрической системе координат имеет вид [4]

$$w(\rho) = \frac{1}{1 + \rho^2} \frac{1 - e^2}{1 - e \cos(\varphi - \varphi_0)}, \quad \rho = r/\Delta r, \quad (2)$$

где  $r$  — расстояние между участками (нейронами), излучающими тепло и принимающими его;  $\Delta r$  — расстояние между соседними участками;  $\varphi_0$  — угол наклона большой оси эллипса индикатрисы теплопередачи, задаваемый направлениями ветра и склона;  $e$  — эксцентриситет эллипса индикатрисы, определяемый силой ветра и величиной склона;  $\varphi$  — текущая координата. Сечениями функции активации являются эллипсы, эксцентриситет, длина и ориентация осей которых находятся из расстояния между излучающим и принимающим нейронами, направлением ветра и углом склона горячей площадки.

Тепловой поток, излучаемый горящими участками, взвешенный относительно их функций активации, суммируется на принимающих участках, что соответствует увеличению их энтальпии. Результат суммирования сравнивается с порогом, определяемым числовыми характеристиками возгорания участков: типом растительности, влагосодержанием и т. д. Первая точка на радиусе системы, в которой порог превышен, — это точка воспламенения, она считается точкой расчётного фронта горения.

Такая сеть имеет некоторое сходство с радиальными базисными сетями. Оно состоит в наличии слоя нейронов, создающих поле активации с помощью функций, радиально изменяющихся вокруг выбранного центра и принимающих ненулевые значения только в окрестности данного центра. Аналогичные функции, представляемые в виде (1), называются радиальными базисными функциями (РБФ). В этих сетях роль нейрона заключается в отображении радиального пространства вокруг одиночной заданной точки (центра) либо вокруг группы таких точек, образующих кластер. Суперпозиция сигналов, поступающих от всех нейронов, которая выполняется выходным нейроном, позволяет получить отображение полного многомерного пространства. Классический метод построения нейросетей на основе РБФ и использования их для аппроксимации функций опирается на то, что такие сети имеют центросимметричный вид, а расположение их центров и масштаб ищутся путём обучения нейросети. Мы же, следуя изложенному в [5] предположению о том, что применение РБФ для моделирования распределённых систем может быть существенно расширено, примем следующую схему: расположение центров РБФ изначально задаётся кластером находящихся на радиусе возбуждённых нейронов, соответствующих горящим




Рис. 1

участкам, а их функции активации, представляемые в виде (2), являются переменными, параметры которых  $(e, \varphi_0)$  должны быть установлены в процессе обучения. В качестве критерия обучения используются координаты фронта горения, получаемые в результате космического или аэронаблюдения за пожаром.

Схема нейронной сети с привязкой её к области пожара приведена на рис. 1. Будем считать, что наблюдение за пожаром ведётся с периодичностью  $\Delta t$ ,  $k$  — индекс этапа, на котором производится теплопередача, а затем и коррекция индикатрис теплопередачи. Координаты нейронов определяются в полярной системе координат  $(r, \varphi)$ :  $\varphi = \Delta\varphi i$ , здесь  $i$  — номер луча, где располагаются нейроны  $N_{ij}$  ( $i = 1, \dots, n_l$ ),  $n_l$  — число лучей;  $r = \Delta r j$  — радиальная координата нейрона. Общее число нейронов в сети  $n$ . Сигналы, циркулирующие в нейронной сети, пропорциональны тепловым потокам в области пожара, далее для краткости будем называть их тепловыми потоками.

Поскольку за фронтом горения располагается некоторая область горения, имеется множество нейронов  $\bigcup_{j=m}^{j=m+n_a} N_{ij}$ , располагающихся на  $i$ -м луче, где  $n_a$  — число активных нейронов,  $m$  — номер нейрона, соответствующего внутренней границе фронта горения.

Суммарное тепловое поле  $I_{ij\Sigma}$ , накапливаемое нейроном  $N_{ij}$  на  $k$ -м этапе, вычисляется из выражения

$$I_{ij\Sigma} = \sum_{i=1}^{n_l} \sum_{j=m}^{j=m+n_a} I_{ij} w_{ij}(\rho). \quad (3)$$

Здесь  $w_{ij}(\rho)$  — индикатриса теплопередачи, определяющая, от каких нейронов и с каким весом интегрируются тепловые потоки в нейроне  $N_{ij}$ .

Когда суммарный тепловой поток нейрона  $N_{ij}$  превысит порог, определяемый характером материала и влажностью участка, соответствующего этому нейрону, происходит воспламенение и нейрон переходит в стадию возбуждения. Каждый из  $n_a$  возбуждённых нейронов на  $i$ -м луче образует систему синаптических связей с соседними нейронами в соответствии с индикатрисой теплопередачи  $w_{ij}(\rho)$ . Параметры этой индикатрисы задаются скоростью ветра, углом склона, характером горючего материала.

На каждом этапе точки контура пожара будут перемещаться по лучам на величину  $d_i$ . На эту же величину будут перемещаться и два слоя нейронов: слой возбуждённых нейронов, соответствующий горящему участку, и слой возбуждаемых нейронов, относящийся к участкам, накапливающим тепло. Что касается всех остальных участков, то они либо сгорели, либо ещё не нагреваются и интереса для нас не представляют. Таким образом, имеем неполносвязную рекуррентную нейронную сеть [6], перемещающуюся по лучам. Первый слой — это слой входных нейронов, второй — слой скрытых нейронов. Блок-схема такой нейронной сети представлена на рис. 2.

В то же время результаты космического или аэронаблюдения дают истинное перемещение точки пожара по  $i$ -му лучу  $d_i^*$ . Традиционное обучение нейронной сети состоит в корректировке синаптических связей (обучении сети) до тех пор, пока не выполнится  $(d_i - d_i^*)^2 < \varepsilon$ . Однако такое обучение не учитывает модели нейронной сети и поэтому происходит очень медленно. Ускорить обучение можно с помощью применения калмановской фильтрации [7]. Начнём её объяснение с описания движения фронта пожара в рамках пространства состояний. Очень важно, что взять в качестве компонентов вектора состояния системы. Это могут быть параметры внешней среды, задающие движение фронта по лучам на  $k$ -м этапе: направление и скорость ветра, влагосодержание и другие в зависимости от выбранной модели или параметры индикатрисы теплопередачи. Как уже отмечалось, она представляет собой эллипс, характеризующийся тремя составляющими: размером большой полуоси  $z_0$ , эксцентриситетом  $e$  и наклоном большой полуоси  $\varphi_0$  [8]. Нами использован второй вариант, поскольку он лучше характеризует нейросеть (зная параметры индикатрис, можно сразу же построить синаптические связи). Считаем, что для  $i$ -го луча и  $k$ -го этапа для всех  $n_{ai}$  нейронов луча вектор состояния одинаков. Тогда в глобальной модели сети размер вектора состояния  $W(k)$  будет  $z = n_l s$ , где  $s$  — число параметров (в нашем случае  $s = 3$ ). Размер вектора измерения  $d(k)$  равен  $n_l$  (по числу лучей).




Рис. 2

Перемещение фронта запишем в виде

$$d_i(k) = C(W(k), \beta(k)) + \beta(k), \quad (4)$$

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, приведёт 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 (3), представив его в виде

$$d_i(k) = CW(k) + \beta(k), \quad (5)$$

где матрица  $C$  измерения линеаризованной модели размера  $z$  находится из выражения

$$C = \begin{pmatrix} \partial c_1/\partial w_1 & \partial c_1/\partial w_2 & \dots & \partial c_1/\partial w_z \\ \partial c_2/\partial w_1 & \partial c_2/\partial w_2 & \dots & \partial c_2/\partial w_z \\ \dots & \dots & \dots & \dots \\ \partial c_p/\partial w_1 & \partial c_p/\partial w_2 & \dots & \partial c_p/\partial w_z \end{pmatrix}. \quad (6)$$

В этом случае требуются операции с матрицами больших размеров, поэтому перейдём к модели несвязного расширенного фильтра Калмана. В соответствии с этой моделью выделим  $n_l$  (по числу лучей) групп нейронов. Каждая  $i$ -я группа состоит из  $n_{ai}$  входных нейронов и  $n_{pi}$  нейронов скрытого слоя, соединённых с первыми нейронами синаптическими связями, которые определяются параметрами вектора состояния  $z_i = s$ . Основным отличием предлагаемой модели от известных [6] 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,  $p = \sum_{i=1}^{n_l} n_{pi}$ .

Рассмотрим применение алгоритма фильтрации Калмана. Для линеаризованной динамической модели

$$\Gamma(k) = \left[ \sum_{i=1}^{n_l} C_i(k)K_i(k \| k-1)C_i^T(k) + R(k) \right]^{-1}, \quad (7)$$

$$G_i(k) = K_i(k \| k-1)C_i^T(k)\Gamma(k), \quad (8)$$

$$\alpha(k) = d^*(k) - d(k \| k-1), \quad (9)$$

$$\hat{w}_i(k+1 \| k) = \hat{w}_i(k \| k-1) + G_i(k)\alpha(kn), \quad (10)$$

$$K_i(k+1 \| k) = K_i(k \| k-1) - G_i(k)C_i(k)K_i(k \| k-1). \quad (11)$$

Здесь  $C_i$  — составная часть матрицы  $C$  для  $i$ -го блока;  $\Gamma(k)$  — матрица размера  $p \times p$ , представляющая собой глобальный коэффициент передачи для всей сети;  $G_i(k)$  — матрица размера  $s \times p$ , обозначающая коэффициент усиления Калмана для  $i$ -й группы составляющих вектора состояния;  $\alpha(k)$  — вектор размера  $n_l$ , представляющий невязку, определяемую как разность желаемого отклика  $d(k)$  линеаризованной системы и его оценки  $d(k \| k-1)$ , основанной на входных данных, доступных в момент времени  $k-1$ :  $d(k \| k-1) = C(k)\hat{w}(k \| k-1)$ ;  $\hat{w}_i(k \| k-1)$  — вектор размера  $s \times 1$ , являющийся оценкой вектора состояния  $\hat{w}_i(k)$  для  $i$ -й группы в момент времени  $k$  при наличии наблюдаемых данных вплоть до момента времени  $k-1$ ;  $K_i(k \| k-1)$  — матрица размера  $s \times s$ , 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 из выражения

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

Как показано в [7], в уравнение (10) 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 (10) преобразуется в

$$K_i(k+1 \| k) = K_i(k \| k-1) - G_i(k)C_i(k)K_i(k \| k-1) + Q_i(k). \quad (12)$$

С учётом (12) полная процедура расщепления расширенного фильтра Калмана выглядит следующим образом.

*Инициализация:*

- 1) параметры индикатрис теплопередачи  $w(\rho)_0$  задаются согласно имеющимся априорным данным (параметрам ветра, склона, горючей среды);
- 2) в ковариационной матрице  $Q_i(k)$ , характеризующей искусственно введённый шум  $\omega_i(k)$ , диагональные элементы устанавливаются в диапазоне от  $10^{-3}$  до  $10^{-2}$ ;
- 3) начальное значение ковариационной матрицы ошибок  $K_i(k \| k-1)$  полагается  $K_i(1 \| 0) = \delta^{-1}I$ , где  $\delta$  — малый наперёд заданный вектор.

*Вычисления:*

- 1) для  $k = 1, 2, 3, \dots$  последовательно находятся рекурсивные соотношения (7)–(11);
- 2) ещё раз определяются все переменные:  $c_i(n)$  вычисляется с использованием (4), (5) ( $c_i = \Delta c_i / \Delta w_i$ ), т. е. путём придания малых изменений  $w(\rho)$ ;  $K_i(0 \| 1)$  задаётся в соответствии с п. 3 инициализации, а последующие значения  $K$  получаются рекуррентно относительно (12);
- 3)  $R(k)$  выводится исходя из ошибки измерения положения фронта пожара;
- 4)  $d_i(k)$  — перемещение фронта пожара, измеряемое системой наблюдения;
- 5)  $d_i(k \| k-1) = C(k)\hat{w}_i(k \| k-1)$ , где  $w_i(1 \| 0)$  — начальное значение вектора состояния, определяемое априорными сведениями об индикатрисе теплопередачи, зависящими от направления и силы ветра, влажности и т. д.

Последующие значения вычисляются рекуррентно в соответствии с (10).

Отметим, что в связи с зависимостью перемещения фронта  $d_i(k)$  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  $\alpha(k) = d^*(k) - \hat{d}(k \parallel k - 1) < \delta$ .

**Оценка эффективности обучения с использованием калмановской фильтрации.** Как уже отмечалось, распространение тепла от горящей ячейки на соседние может быть выражено с помощью индикатрисы теплопередачи, представляющей собой эллипс. С её помощью рассчитываются синаптические связи между возбуждённым и окружающими нейронами в состоянии накопления сигнала. Также возможна и обратная операция, когда по синаптическим связям нейрона восстанавливается индикатриса теплопередачи. Для сравнения времени обучения примем вторую схему, когда после проведения процедуры коррекции для каждого активного нейрона имеем скорректированный набор синаптических связей с остальными нейронами, и по этому набору восстанавливается индикатриса теплопередачи. Считая, что параметры среды однородны (значения между соседними ячейками изменяются плавно), индикатрису теплопередачи для перешедших в состояние возбуждения нейронов можно рассчитывать как среднюю по соседним ячейкам.

Существенное время на каждом шаге прогноза занимает обучение нейронной сети. Произведём временную оценку представленных в данной работе методов обучения. Обозначим характерные времена процессов, происходящих во время обучения, и используемые величины:

- 1)  $T_W$  — время расчёта весовых коэффициентов синаптических связей нейрона по индикатрисе теплопередачи соответствующей ему ячейки;
- 2)  $T_P$  — время расчёта передачи сигнала от нейрона на все остальные нейроны, связанные с ним;
- 3)  $T_E$  — время расчёта ошибки прогнозирования; ошибка обучения определяется как число ячеек, для которых реальное состояние отличается от полученного в ходе моделирования;
- 4)  $T_{Ln}$  — время процедуры корректировки синаптических связей с учётом ошибок прогнозирования; коррекция синаптических связей осуществляется по формуле

$$w_{ab}(k + 1) = w_{ab}(k)(1 + \varepsilon), \quad (13)$$

где  $w_{ab}$  — весовой коэффициент между нейронами  $a$  и  $b$ ;  $k$  — номер шага;  $\varepsilon$  — учёт ошибки прогнозирования (если действительное состояние ячейки активное, а спрогнозированное нет, то  $\varepsilon = 1$ , если одинаковы, то  $\varepsilon = 0$ , иначе  $\varepsilon = -1$ );

- 5)  $T_{Ind}$  — время восстановления индикатрисы теплопередачи ячейки.

В случае простого обучения восстановление осуществляется по синаптическим связям соответствующего ячейке нейрона, в случае же калмановской фильтрации индикатриса обновляется по формулам модели несвязного расширенного фильтра Калмана. Хотя описанные процедуры восстановления индикатрисы и неэквивалентны, они определяются относительно одинаковыми временами, поэтому для них используется общее обозначение.

Оценим время обучения на каждом шаге для метода простого обучения, основанного на обучении нейронной сети с последующим восстановлением индикатрис теплопередачи для каждой ячейки среды. Процедура представлена в виде блок-схемы на рис. 3, а. Осуществляются расчёт весовых коэффициентов и передача сигнала для всех активных нейронов  $(T_W + T_P)n_a$ , затем происходит сравнение реального фронта пожара и полученного в результате прогнозирования  $T_E$ . Если ошибка больше порогового значения, то производится обновление весов нейронов с учётом ошибки прогнозирования  $T_{Ln}$ . До тех



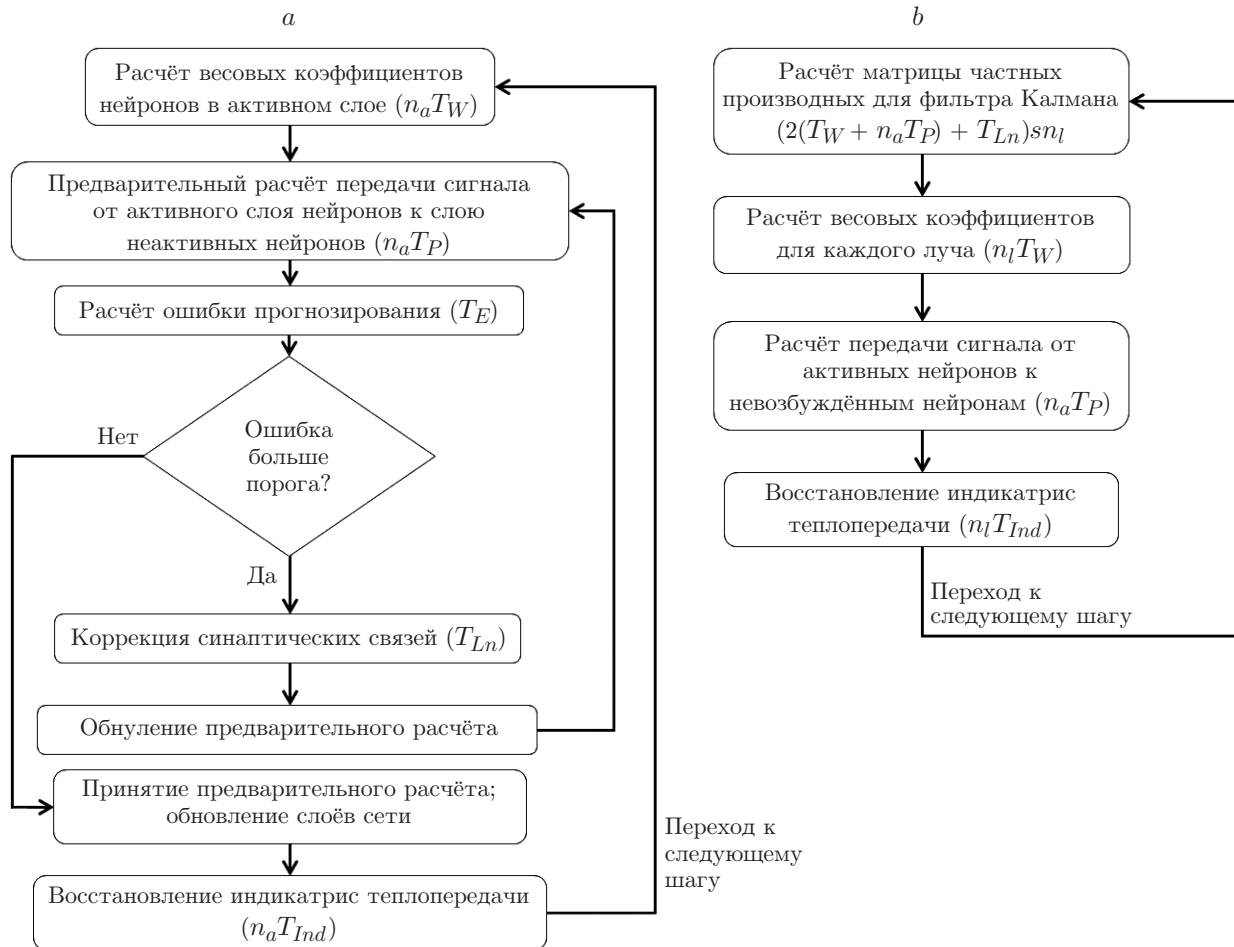


Рис. 3

пор пока ошибка не будет меньше порогового значения, все вышеописанные шаги за исключением расчёта весовых коэффициентов повторяются. После этого на основе обновлённых весовых коэффициентов восстанавливается индикатриса для всех ячеек, соответствующих нейронам в активном слое  $T_{Ind}n_a$  и рассчитывается заключительная итерация шага с новыми весовыми коэффициентами  $(T_W + T_P)n_a$ . Таким образом, на каждом шаге в процессе обучения затрачивается время

$$(T_P n_a + T_E + T_{Ln})\theta + T_{Ind}n_a + (T_W + T_P)n_a, \quad (14)$$

где  $\theta$  — число итераций.

Оценим теперь время обучения с использованием калмановской фильтрации (рис. 3, *b*). Для каждого луча производится расчёт весовых коэффициентов  $T_W n_l$  и предварительный расчёт передачи сигналов от активного слоя нейронов к неактивному  $n_a T_P$ . Затем обновляются параметры фильтра. В данной работе применялась наиболее быстрая вариация нелинейного калмановского фильтра — несвязный расширенный фильтр Калмана, использующий матрицу частных производных  $C$  для обновления вектора состояний. Таким образом, для каждого параметра системы, содержащегося в векторе состояния, необходимо рассчитать частную производную численными методами приданием малых приращений параметру. На расчёт одного параметра затрачивается  $2(T_W + T_P n_a) + T_E$  (двойка возникает при положительном и отрицательном приращении). Для того чтобы обновить параметры фильтра для всех лучей, требуется затратить  $n_l s(2(T_W + T_P n_a) + T_E)$  тактов.

После обновления параметров фильтра производится корректировка индикатрисы теплопередачи  $T_{Ind}n_l$ . Конечная формула оценки времени обучения имеет вид

$$T_W n_l + T_P n_a + n_l s (2(T_W + T_P n_a) + T_E) + T_{Ind} n_l. \tag{15}$$

Сравним (14) и (15), рассчитав отношения перед каждым из основных слагаемых  $T_W$ ,  $T_P$ ,  $T_{Ln}$ ,  $T_{Ind}$  с учётом  $T_{Ln} \cong T_E$  соответственно:

$$\frac{(2s + 1)n_l}{n_a}, \quad \frac{2sn_l + 1}{r + 1}, \quad \frac{sn_l}{r}, \quad \frac{n_l}{n_a}.$$

Видно, что основными величинами, характеризующими данные отношения, являются число параметров, число итераций и отношение числа лучей к числу активных нейронов  $n_l/n_a$ . Как уже отмечалось, в качестве индикатрисы теплопередачи используется эллипс, тогда  $s = 3$ . Число итераций во многом зависит от скорости обучения сети  $\eta$ . На рис. 4 представлена зависимость среднего времени шага от скорости обучения. При оптимальной скорости обучения и обучении на каждом шаге число итераций не больше десяти. Таким образом, можно принять  $r \cong 10$ .

Итерации повторяются до тех пор, пока не будет выполнено требование по невязке, и их число зависит от скорости обучения. Графики на рис. 5 иллюстрируют, что при скорости 0,5 (сплошная кривая) число итераций существенно ниже, чем при скорости 0,05 (штриховая кривая).

При калмановской фильтрации точность прогноза зависит от количества нейронов в луче, поэтому данная величина не должна превосходить определённый порог. Положим максимальное число нейронов в луче 100, тогда  $n_l/n_a > 0,01$ . Исходя из этих оценок, на каждом шаге получаем выигрыш по временам  $T_W$  и  $T_{Ind}$ . Однако с расширением области протекания процесса растёт и количество лучей. При числе лучей больше пяти имеем проигрыш по  $T_P$  и  $T_E$ , а при числе лучей, превышающем 300–400 (что составляет по лучу на градус), — по суммарному времени прогноза. Если не снижать точность прогноза калмановской фильтрации относительно простого обучения, то число лучей равное 300 достигается при прохождении фронтом пожара расстояния 100–150 ячеек от центра. На основании этого можно сделать вывод, что фильтрация Калмана даёт выигрыш в случае небольших пожаров радиусом меньше 100–150 м (если принять размер ячейки 1 м), в остальных случаях лучше применять простое обучение. На рис. 6, *a, b* показаны зависимости времени прогноза и числа нейронов от номера шага для простого обучения (штриховые кривые) и обучения с использованием фильтра Калмана (сплошные кривые).




Рис. 4




Рис. 5

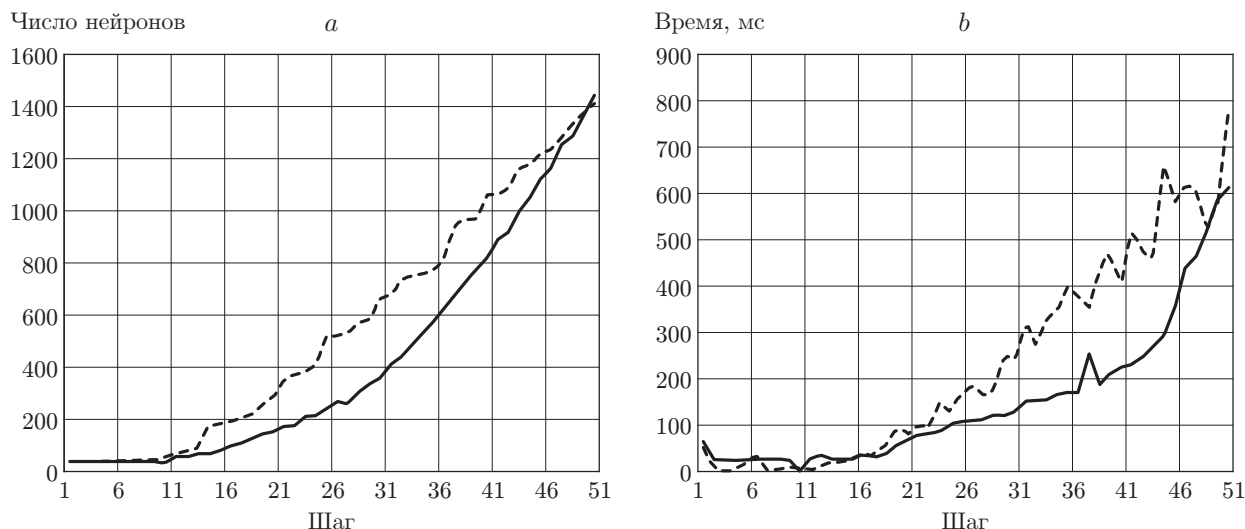


Рис. 6

Оценивая фильтрацию качественно, можно утверждать, что она позволяет достичь более быстрой и точной сходимости к реальным данным, так как учитывает уравнения, определяющие функционирование модели, а также возможные ошибки системы наблюдения пожара. Поэтому использование калмановской фильтрации оправдано не только в случаях небольших пожаров, но и в других ситуациях.

**Заключение.** В предлагаемой работе показано, что моделирование лесного пожара рекуррентной нейронной сетью позволяет производить процесс усвоения данных пожара путём сравнения прогноза распространения пожара, выполненного с помощью компьютерного моделирования, и реального наблюдения области распространения пожара космическими или аэросредствами. Усвоение данных даёт возможность существенно снизить влияние на результат моделирования априорной неопределённости (практически всегда присущей динамическим процессам, в том числе и пожарам, на поверхности Земли), связанной с плохо предсказуемыми изменениями внешних условий. Поскольку рассматриваемый метод может применяться в оперативной обстановке для ускорения процесса усвоения данных, реализуемого путём 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 пожара. Сравнительный анализ простого процесса обучения и обучения с помощью калмановской фильтрации позволил выяснить, при каких параметрах модели выгодно её применять.

### СПИСОК ЛИТЕРАТУРЫ

1. **Kozik V. I., Nezhevenko E. S., Potaturkin O. I.** Adaptive modeling of discontinuous dynamic processes based on images sequence analysis // Proc. of the World Multiconference on Systemics, Cybernetics and Informatics (SCI-2001). Orlando, USA, 2001. Vol. XIII, Pt. II. P. 41–44.
2. **Kozik V. I., Nejevenko E. S.** Neural network simulation of dynamic processes above ground // Proc. of the IASTED Intern. Conf. "Automation, Control, and Information Technology (ACIT'2002)". Anaheim — Calgary — Zurich: ACTA Press, 2002. P. 196–200.
3. **Rothermel R. C.** A Mathematical Model for Predicting Fire Spread in Wildland Fuels. Ogden, USA: Intermountain Forest and Range Exp. Stn., USDA Forest Service, 1972. Res. Paper INT-115. 40 p.

- 
4. **Dumond Y.** Forest fire growth modelling with geographical information fusion // 11th Intern. Conf. on Information Fusion (FUSION'08) [CD-ROM]. Cologne, Germany, July, 2008. 6 p.
  5. **Васильев А. Н., Тархов Д. А.** Новые подходы на основе RBF-сетей к решению краевых задач для уравнения Лапласа на плоскости // Нейрокомпьютеры: разработка, применение. 2004. № 7–8. С. 119–126.
  6. **Haykin S.** Neural Networks. Upper Saddle River: Prentice Hall, 1999. 842 p.
  7. **Kalman** Filtering and Neural Networks /Ed. S. Haykin. John Wiley & Sons, Inc., 2001. 284 p.
  8. **Доррер Г. А.** Динамика лесных пожаров. Новосибирск: Изд-во СО РАН, 2008. 402 с.

*Поступила в редакцию 29 июня 2012 г.*

---