

ОПЕРАТИВНОЕ ПРОГНОЗИРОВАНИЕ ПРИРОДНЫХ КАТАСТРОФ С ИСПОЛЬЗОВАНИЕМ ТЕХНОЛОГИЙ НЕЙРОННЫХ СЕТЕЙ

В.И.Замай, Т.И. Курманалиев, Е.Л.Миркин, Ж.А.Мусакулова, Е.Ю.Савченко
Институт автоматизации и информационных технологий НАН КР, vzamai@mail.ru;
Международный университет Кыргызстана, hsnit@rambler.ru

Спутниками человеческой активности являются всё возрастающие по своей мощности природные и техногенные катастрофы, которые ежегодно приносят огромный материальный ущерб, поглощают человеческие жизни.

Мир опасностей непрерывно растет, а методы их прогнозирования и средства защиты от них создаются и совершенствуются со значительным опозданием. За последние 40 лет ущерб от природных и техногенных катастроф вырос в 9 раз, а их частота увеличилась в 5 раз [1–4].

Испытывая на себе результаты разрушающего действия воды, ветра, землетрясений, снежных лавин и селей, человек издавна использовал элементы мониторинга, накапливая опыт предсказания погоды и стихийных бедствий. Такого рода знания всегда были и сейчас остаются необходимыми для того, чтобы по возможности снизить ущерб, причиняемый человеческому обществу неблагоприятными природными явлениями и, что особенно важно, уменьшить риск человеческих потерь.

Прогнозирование – это ключевой момент при принятии решений в управлении. Конечная эффективность любого решения зависит от последовательности событий, возникающих уже после принятия решения. Возможность предсказать неуправляемые аспекты этих событий перед принятием решения позволяет сделать наилучший выбор, который, в противном случае, мог бы быть не таким удачным. Поэтому системы планирования и управления, обычно, реализуют функцию прогноза.

Целью прогнозирования является уменьшение риска при принятии решений. Прогноз обычно получается ошибочным, но величина ошибки зависит от используемой прогнозирующей системы. Предоставляя прогнозу больше ресурсов, мы можем увеличить точность прогноза и уменьшить убытки, связанные с неопределенностью при принятии решений [7-9].

В предлагаемом докладе рассматривается возможность использования нейросетевого модуля для динамического прогнозирования чрезвычайных ситуаций. Способности нейронной сети к прогнозированию напрямую следуют из ее способности к обобщению и выделению скрытых зависимостей между входными и выходными данными. После обучения сеть способна предсказать будущее значение некой последовательности на основе нескольких предыдущих значений и/или каких-то существующих в настоящий момент факторов [5,6]. Следует отметить, что прогнозирование возможно только тогда, когда предыдущие изменения действительно в какой-то степени предопределяют будущее.

Применение для предсказания чрезвычайных ситуаций (ЧС) подхода, основанного на использовании нейронных сетей, является актуальным в силу отсутствия математической причинно-следственной модели возможности возникновения ЧС и наличия большого статистического массива данных наблюдения.

Заметим, однако, что количество случаев ЧС в общей доли статистических наблюдений является ничтожно малым – одно два на 30 – 50 лет в зависимости от вида ЧС. Поэтому актуальным также является формирование большого массива данных ЧС по нескольким реально произошедшим случаям ЧС. Но для качественного обучения нейронной сети требуется большой массив данных. При этом генерация виртуальных чрезвычайных ситуаций, похожих на реальные ЧС, является достаточно сложным и трудоемким процессом. Однако если мнения группы экспертов формализовать в механизмы влияния наиболее значимых факторов на вероятность возникновения события ЧС, то можно создать компьютерную программу, генерирующую массив данных, соответствующий виртуальным чрезвычайным ситуациям.

Идею динамического прогноза ЧС реализуем путем построения цепочки последовательно соединенных блоков, каждый из которых дает прогноз интересующего исследователя показателя на один временной интервал вперед.

В качестве примера, рассмотрим нейросетевую модель, для прогнозирования чрезвычайной ситуации образования паводковой опасности в бассейне реки Алаарча.

По мнению большинства исследователей [1, 2, 5], основных факторов окружающей среды, составляющих прогнозный фон процесса образования паводков достаточно много, но наиболее существенное влияние на уровень паводковых вод оказывают следующие факторы:

- температурный фон (температура воздуха за 6–8-дневный период наблюдения) в паводко-образующем бассейне (в условиях высокогорья с ледниковыми системами);
- интенсивность осадков, их длительность, влажность грунта на момент прогноза;
- расход воды в русле (на момент прогноза);
- площадь водосбора паводко-образующего бассейна;
- рельеф местности (крутизна гор, уклон русла, шероховатость русла, откос русла, ширина по дну русла);
- впитывающая способность грунта водосбора, а также характеристики и свойства почвенных структур, видов растительности.

Первые три фактора являются переменными и зависят от погодных условий в районе паводко-образующего бассейна. Последующие три (4,5,6) фактора определяют мало изменяемый квазистационарный набор параметров, характеризующих географические особенности местности паводко-образующего бассейна. Очевидно, что наблюдения, проводимые за переменными параметрами (гидрометеостанции или посты МЧС), являются ценным массивом информации, который способен пролить свет на причинно следственные связи, вызывающие ЧС. Однако, чаще всего, эти ценные данные хранятся в бумажном виде и не могут быть оперативно востребованы для целей прогноза. Понятно также, что этот массив накопленной информации учитывает географические особенности местности паводко-образующего бассейна. Таким образом, использование нейросетевого подхода для прогнозирования ЧС, является актуальным в связи со спецификой использования технологии нейронных сетей.

Для создания нейросетевого блока прогнозирования ЧС на один временной такт определим следующие этапы его синтеза:

- определение количества и наименования входных и выходных параметров нейросетевого блока, а также определение временного интервала, соответствующего одному такту прогноза;
- выбор топологии нейросетевого блока и алгоритма его обучения;
- формирование и нормировка массива данных, предназначенных для обучения нейросетевого модуля.

В качестве входных параметров данного блока будем использовать три наиболее значимых переменных измеряемых за сутки параметра:

1. Среднесуточная температура воздуха в i -ый день (С) – T_i ;
2. Количество осадков, выпавшее за сутки в i -ый день (mm) – O_i ;
3. Среднесуточный расход воды в русле паводко-образующего бассейна в i -ый день (куб.м/сек) – R_i ;

Очевидно, что среднесуточный расход воды в русле R_i , в нашем случае является показателем, определяющим факт ЧС паводка в бассейне реки. Так во время паводка в бассейне реки Алаарча, произошедшего 22 июля 2003 года, расход воды в русле реки составил 30,9 куб.м/сек. Таким образом, наблюдая за этим показателем и предсказывая его, можно оперативно связывать расход воды в русле реки с возможностью возникновения паводка (ЧС) в паводко-образующем бассейне реки Алаарча.

Заметим также, что ЧС не происходит внезапно и мгновенно, она готовится в течение определенного промежутка времени (в случае паводка, по мнению большинства экспертов,

это шесть дней, включая день прогноза). Подготовка ситуации определяется температурным фоном, количеством и интенсивностью осадков за данный период. А также динамикой изменения расхода воды в русле паводко-образующего бассейна.

Таким образом, для того чтобы учесть историю подготовки ЧС, в качестве входных параметров нейросетевого блока будем использовать шестидневную историю измеряемых параметров T_i , O_i , R_i ($i=1,2,3,4,5,6$), то есть 18 входных параметров. В качестве выходного параметра нейросетевого модуля будем использовать расход воды в седьмой день – R_7 , то есть один выходной параметр. Структурная схема нейросетевого блока, связывающая входные параметры с выходным представлена на рисунке 1.

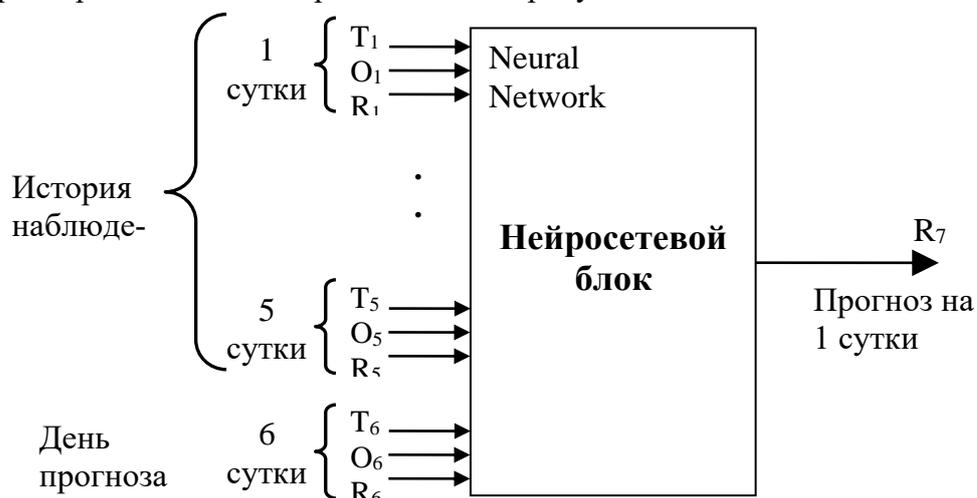


Рисунок 1. Схема преобразования данных в нейросетевом модуле.

Очевидно, что обученный нейросетевой модуль способен в будущем прогнозировать расход воды в паводко-образующем бассейне реки Алаарча на сутки вперед.

Зададим топологию нейросетевого блока в виде трехслойного персептрона с 18 нейронами в первом слое, 18 нейронами во втором слое и одним нейроном в выходном слое. Таким образом, общее количество нейронов в блоке будет равно 37. Структурная схема топологии нейросетевого блока представлена на рисунке 2.

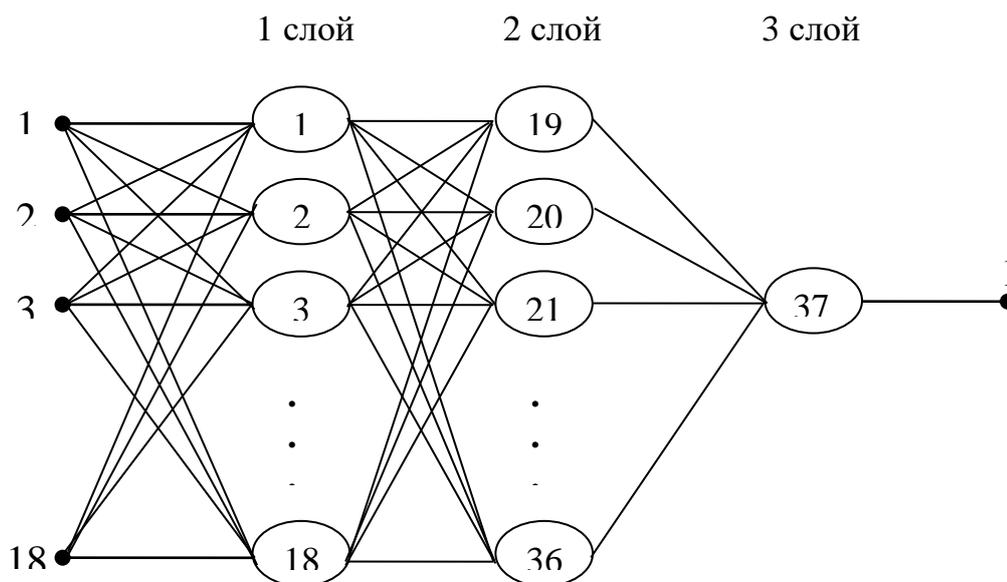


Рисунок 2. Структурная схема топологии нейросетевого модуля (трехслойный персептрон).

Количество весовых коэффициентов настраиваемой нейронной сети составит $18 \cdot 18 + 18 \cdot 18 + 18 + 1 = 667$.

Существует большой спектр алгоритмов обучения нейронной сети, например градиентный, алгоритм обратного распространения и т.д. Для нашего – случая формирования ошибки обучения в виде квадратичной функции, наиболее подходящим считается алгоритм Ливенберга–Марквардта.

Для качественного обучения нейронной сети выбранной топологии (см. рисунок 2), необходимо иметь достаточно большой массив данных, полученных в результате наблюдения за чрезвычайной ситуацией в паводко-образующем бассейне реки Алаарча. Однако, как уже было отмечено выше, ЧС случаются достаточно редко. Данные наблюдений Гидрометеоцентра во время паводка в бассейне реки Ала–Арча, произошедшего 22 июля 2003 года, представлены в таблице.

Таблица. Данные наблюдения Гидрометеоцентра во время паводка в бассейне реки Алаарча.

Алаарча – устье реки Кашка-Суу			
	Среднесуточная температура	Количество осадков за сутки	Среднесуточные расходы воды за июль 2003 г.
Дата			
13	12,0		19,5
14	11,0		18,9
15	10,5	9,9	17,7
16	11,0	8,6	17,0
17	12,5		18,3
18	14,0		18,3
19	15,5		17,7
20	15,5		18,9
21	<u>19,0</u>	25,2	21,5
22	<u>15,0</u>	10,8	30,9
23	<u>15,0</u>	10,0	25,3
24	8,0	2,2	20,3

Ясно, что данных приведенных в таблице 1 недостаточно для обучения нейронной сети. Необходимо сгенерировать виртуальные чрезвычайные ситуации, похожие на реально произошедшую чрезвычайную ситуацию. Для этого была создана компьютерная программа, генерирующая массив данных соответствующий виртуальным чрезвычайным ситуациям. В созданной программе мнения группы экспертов должны быть формализованы в механизмы влияния наиболее значимых факторов на вероятность возникновения события ЧС.

Для обучения и тестирования, обученной нейронной сети, использовался пакет MATLAB и его toolbox Neural Network. Массив данных виртуальных ЧС был считан из файла, нормирован и подан на вход нейронной сети. Модуль нейронной сети был сконфигурирован как трехслойный персептрон с 18 нейронами в первом слое, 18 нейронами во втором и одним нейроном в выходном слое. В качестве алгоритма обучения сети был выбран алгоритм Ливенберга–Марквардта с сигмоидальными функциями активации. Были определены следующие параметры обучения нейронной сети: количество эпох обучения – 120; точность обучения (остановка по величине градиента $1E-10$).

Качество обучения нейронной сети демонстрирует рисунок 3.

Как видно из рисунка 3, ошибка обучения нейронной сети уменьшилась со значения 0,459 до величины 0,000496, что говорит о хорошем качестве обучения нейросетевого модуля.

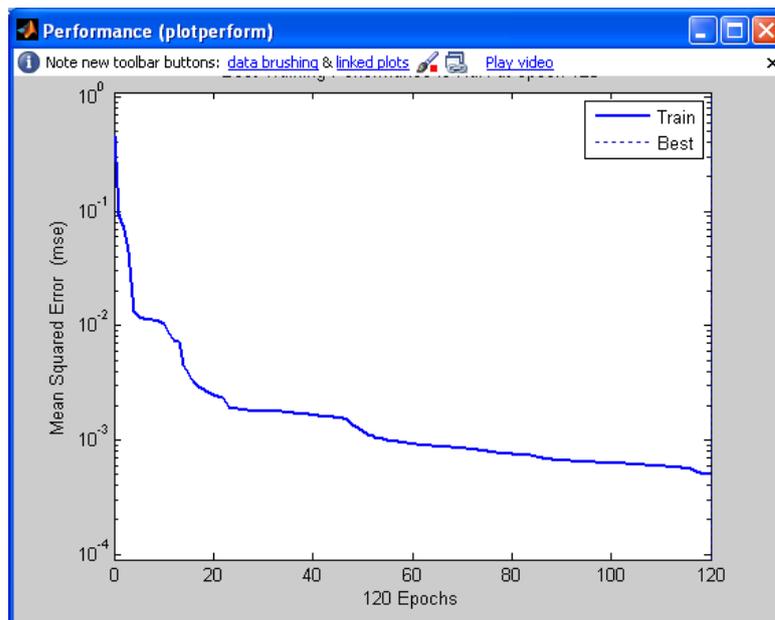


Рисунок 3. Качество обучения нейронной сети.

Обучение нейронной сети проходило на массиве данных, полученных с помощью программы генерации виртуальных ЧС, из которого была исключена реально измеренная точка ЧС – паводка, произошедшего 22 июля 2003 года (см. таблицу). Тестирование обученной нейронной сети было проведено для точки реальной ЧС. Точность прогноза составляет 1,4 %, что говорит о хорошей прогнозирующей способности нейросетевого модуля.

Таким образом, предложена и сконфигурирована нейронная сеть для решения задачи прогнозирования паводковой опасности в бассейне реки Алаарча на один временной интервал вперед. Полученный нейросетевой модуль, обучен на массиве данных виртуальных ЧС и протестирован на реальном событии, произошедшим 22 июля 2003 года.

Литература.

1. Флейшман С.М., Перов В.Ф. Сели. – М.: Изд-во МГУ, 1986.
2. Замай В.И. Исследование прогнозного фона паводковой и селевой опасности на основе данных мониторинга чрезвычайного события // Проблемы автоматки и управления – Бишкек: Илим, 2008. – С. 97–103.
3. Прогностика. Терминология. Вып. 92. – М.: Наука, 1978.
4. Сидельников Ю.В. Теория и организация экспертного прогнозирования. – М.: ИМЭМО АН СССР, 1990. – 196 с.
5. Саймон Хайкин. Нейронные сети. Полный курс. 2-ое изд. М., СПб., Киев: Вильямс. 2006. – 1104с.
6. Круглов В.В., Голунов Р.Ю. Нечеткая логика и искусственные нейронные сети. — М.: Физматлит, 2001. – 532с.
7. Розенблатт Ф. Принципы нейродинамики.– М.: Мир, 1965. – 387с.
8. Уоссермен Ф. Нейрокомпьютерная техника: теория и практика. – М.: Мир, 1992. – 380с.
9. Калан Р. Основные концепции нейронных сетей. – М.: Издательский дом «Вильямс», 2001. – 288с.
10. Галушкин А.И. Теория нейронных сетей. – М.: ИПРЖР, 2000. – 348с.
11. Барский А.Б. Нейронные сети: распознавание, управление, принятие решений. – М.: Финансы и статистика, 2004. – 176с.