

ДОЛГОСРОЧНОЕ ПРОГНОЗИРОВАНИЕ МАКСИМАЛЬНЫХ УРОВНЕЙ ВОДЫ Р. ПЯКУПУР С ИСПОЛЬЗОВАНИЕМ НЕЙРОСЕТЕВЫХ ТЕХНОЛОГИЙ

Н.А. Саноцкая

ФГБУ «Арктический и антарктический научно-исследовательский институт» (АНИИ), Санкт-Петербург

Актуальность повышения достоверности гидрологических прогнозов только повышается. Особенно важны гидрологические прогнозы на северных реках, с учетом их транспортного значения. В статье представлен алгоритм долгосрочного прогнозирования уровней воды с помощью нейросети с привлечением суточных значений метеорологических параметров.

Ключевые слова: гидрологические прогнозы, уровни воды, долгосрочный прогноз, нейросеть.

LONG-TERM FORECASTING OF THE MAXIMUM WATER LEVELS OF THE PYAKUPUR RIVER USING NEURAL NETWORK TECHNOLOGIES

N.A. Sanotskaya

*Arctic and Antarctic Research Institute (AARI),
St. Petersburg*

The relevance of improving the reliability of hydrological forecasts is only increasing. Especially important are hydrological forecasts for the northern rivers, taking into account their transport significance. The article presents an algorithm for long-term forecasting of water levels using a neural network using daily values of meteorological parameters.

Key words: hydrological forecasts, water levels, long-range forecast, neural network.

Долгосрочное прогнозирование максимальных уровней воды является весьма сложной задачей вообще и в Арктической зоне РФ в частности. Связано это с тем, что на максимальный уровень воды оказывает влияние множество факторов. Основными из них являются: дождливая осень, су-

ровая зима, большое снегонакопление, запоздалая холодная весна (или же ранняя весна, но очень дружная) с большим количеством осадков, резкое установление теплой погоды [1–4].

В последнее время активно развиваются методы, основанные на нейронных сетях, и они показывают высокую эффективность при решении разнообразных задач, в том числе для прогнозирования уровней воды [5].

Глубокие нейронные сети в настоящее время становятся одним из самых популярных методов машинного обучения. Одна из причин успешного применения глубоких НС заключается в том, что сеть автоматически выделяет из данных важные признаки, необходимые для решения задачи. При обработке больших объемов данных нейронная сеть справляется с выделением признаков гораздо лучше, чем человек.

Объектом исследования выбрана р. Пякупур, которая является левой составляющей р. Пур и протекает по территории Пуровского района Ямало-Ненецкого автономного округа. Гидрологический пост на реке расположен на расстоянии 3,40 км от устья в г. Тарко-Сале. Площадь водосборасоставляет 31 400 км². Пост открыт 01.08.1938 г. и действует в настоящее время. Отметка нуля поста равна 15,31 м БС. Река Пякупур берет свое начало слиянием рек Янкьягун и Нючавотыяха на возвышенности Сибирские Увалы, течет на северо-восток по заболоченной и лесистой низменности.

В качестве исходных данных для построения нейросети выбраны следующие параметры: температура воздуха, температура поверхности почвы, сумма осадков, снежный покров, относительная влажность, дефицит насыщенного водяного пара, температура точки росы, направление ветра, средняя скорость ветра. Значения перечисленных параметров получены с сайта <http://aisori-m.meteo.ru/> с дискретностью в одни сутки и за период с 1 сентября по 28 февраля за весь период наблюдений (до 2020 г.).

Для примера анализа исходных данных представлены колебания дат появления и разрушения снежного покрова и наступления максимальных снегозапасов на графиках рис. 1. По графикам видно, что за период наблюдений с 1936 по 2020 г. значимых трендов в датах не наблюдается.

В связи с тем, что исходные данные являются временными, они сохраняются в трехмерном тензоре с явной осью времени (рис. 2). В соответствии с соглашениями ось времени всегда является второй осью (осью с индексом 1) [6].

Нейронные сети можно рассматривать как сложные геометрические преобразования, выполняющиеся в многомерном пространстве через последовательность простых шагов, состоящих из операций с тензорами.

Для решения задачи использовалось программное обеспечение, реализованное на языке программирования Python в связке с модулями для работы с нейросетями TensorFlow и Keras. Keras – это фреймворк под-

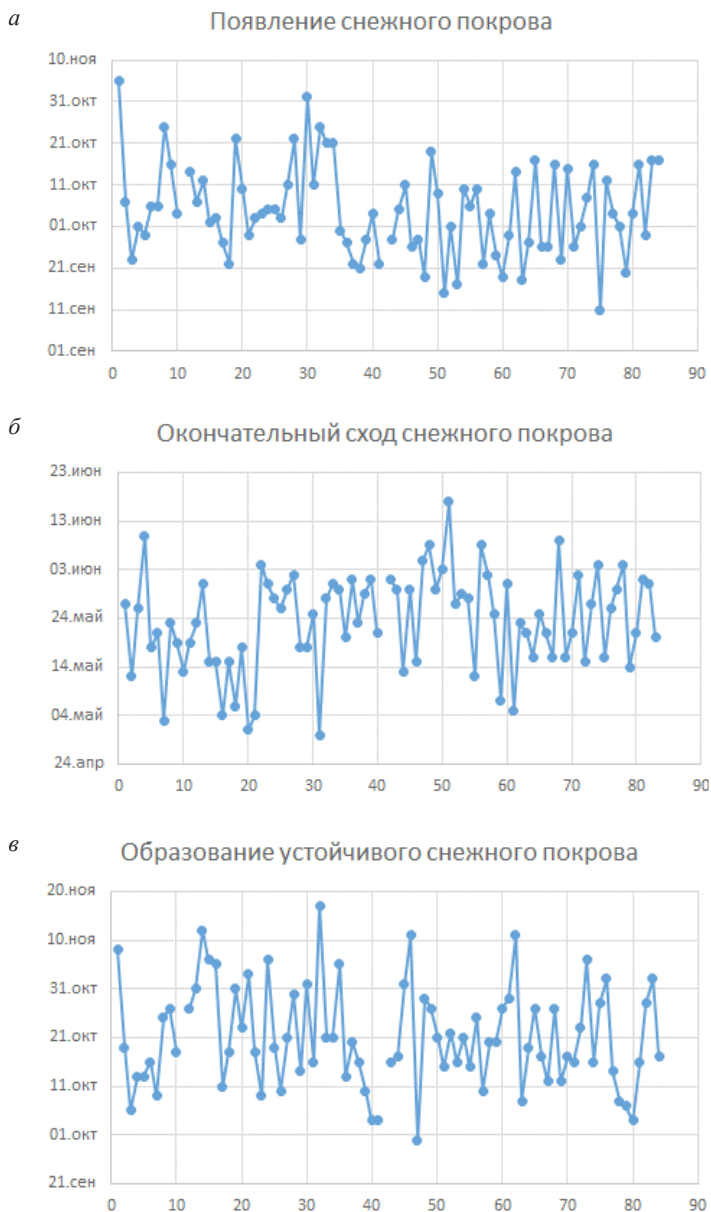



Рис. 1 (начало). Даты образования и схода снежного покрова (а–д) по метеостанции Тарко-Сале за период наблюдений 1936–2020 гг.

2

Сход устойчивого снежного покрова



d

Наступление максимальных снегозапасов




Рис. 1 (окончание).




Рис. 2. Трехмерный тензор с временным рядом

держки глубокого обучения для Python, который предоставляет простой и удобный способ создавать и обучать различные модели глубокого обучения.

Основные подходы к решению задачи:

1) Для решения использовалась сверточная нейросеть. Сеть данной архитектуры обучается быстрее по сравнению с полносвязными нейронными сетями за счет более детального поиска информационных признаков.

2) В качестве функции потерь (loss) использовалась бинарная кросс-энтропия (binary crossentropy) [6]. Для поиска оптимального решения применялся оптимизатор RMSprop. Выбирались модели с максимальным счетом по результатам валидации.

3) Для устранения эффекта «переобучения» введен слой Dropout, который «разряжает» нейронный слой путем поочередного отключения заданного количества.

4) Исходные данные разбиваются на обучающую выборку (1939–2015) и проверочную (2016–2020).

Процесс обучения нейросети можно представить в виде упорядоченной последовательности действий (шагов):

Шаг 1. Сбор исходных данных.

Шаг 2. Представление исходных данных за каждый год в отдельном файле в формате .csv. Название файла является искомым значением.

Шаг 3. Подача на вход нейронной сети массива исходных данных и расчет нейросетью максимального уровня воды.

Шаг 4. Вычисление ошибки между рассчитанными нейросетью максимальными уровнями воды и исходными.

Шаг 5. Корректировка значений весовых коэффициентов нейросети.

Шаг 6. Повторить Шаг 3–Шаг 5 до достижения минимальной ошибки или необходимой точности определения.

Нейронные сети отличаются от математических функций и алгоритмов тем, что требуют обучения перед использованием. Обучение нейронной сети состоит в настройке весов связей между нейронами так, чтобы сеть приближалась к нужной функции с заданной точностью. Существует три метода обучения нейронных сетей: обучение с учителем, обучение без учителя и обучение с подкреплением. При обучении с учителем сети подаются наборы входных сигналов и соответствующие правильные ответы. Веса изменяются в зависимости от правильности выходных сигналов сети. При обучении без учителя входные сигналы не имеют известных правильных ответов. Обучение с подкреплением предполагает взаимодействие сети с внешней средой и основано на получении сигналов от этой среды.

Для обучения нейронных сетей, включая глубокие сети, в настоящее время широко используется алгоритм обратного распространения ошибки, основанный на градиентном спуске. Этот алгоритм использует обучение

с учителем и требует обучающего набора с известными правильными ответами. Мера ошибки определяет, насколько сильно выходные значения сети отличаются от правильных ответов. Затем методом градиентного спуска минимизируется эта ошибка путем изменения весов в сети. Для оценки влияния каждого веса на выходное значение вычисляются частные производные ошибки по весам. Веса изменяются с учетом градиента, и этот процесс повторяется до достижения допустимой ошибки. Начальные значения весов задаются случайным образом.

В глубоких нейронных сетях с несколькими скрытыми слоями ошибка распространяется от выходного слоя к входному. Сначала вычисляется ошибка на выходе сети, для которой известны правильные ответы. Затем вычисляется ошибка на входе выходного слоя, которая используется как ошибка на выходе скрытого слоя. Этот процесс продолжается до тех пор, пока не будет известна ошибка на входе сети. Именно поэтому этот алгоритм называется обратным распространением ошибки.

Цикл обучения включает следующие шаги, которые повторяются столько раз, сколько необходимо:

1. Извлекается пакет x обучающих примеров и соответствующих целей y .
2. Сеть проходит пакет x (этот шаг называется прямым проходом) и получает пакет предсказаний y_{pred} .
3. Вычисляются потери сети на пакете, отображающие расхождение между y_{pred} и y .
4. Корректируются веса сети, чтобы немного уменьшить потери на этом пакете.

В результате сеть показывает очень низкие потери на тренировочном наборе данных, что означает малое расхождение между предсказанными значениями y_{pred} и ожидаемыми целями y . Сеть успешно «научилась» преобразовывать входные данные в правильные выходные значения.

Для решения поставленной задачи использован код на Python, основная содержательная часть которого представляет собой следующее:

```
model = Sequential()
model.add(ZeroPadding2D((1,1),input_shape=(181,16,1)))
model.add(Convolution2D(64, 3, 3, activation='relu'))
model.add(ZeroPadding2D((1,1)))
model.add(Convolution2D(64, 3, 3, activation='relu'))
model.add(MaxPooling2D((2,2), strides=(2,2))).
```

Всего использовано семь слоев. При 20 000 эпох получен удовлетворительный результат (табл. 1). Функция потерь и график ошибок представлены на рис. 3, 4.

Таким образом, в нашей работе представлен способ подготовки входных данных для реализации процесса обучения нейросети. Предложе-

Таблица 1

Результат работы программы

Параметр, см	2016	2017	2018	2019	2020
Расчетное значение уровня воды	995	983	962	969	919
Наблюденное значение уровня воды	965	925	931	949	916
Ошибка	30	58	31	20	3




Рис. 3. График функции потерь




Рис. 4. График изменения значения ошибки в зависимости от эпохи

но использование сверточной нейросети для долгосрочного прогнозирования максимального уровня воды р. Пякупур в створе Тарко-Сале. Заблаговременность прогноза составляет порядка трех месяцев, поскольку в программе используются данные до 28 февраля текущего года при том, что максимальный уровень воды проходит в конце мая–начале июня. Реализация предложенного подхода позволит повысить эффективность долгосрочных прогнозов максимальных уровней.

Литература

1. Разработка на основе математической модели методов и программного обеспечения долгосрочных прогнозов максимальных уровней воды для Средней Оби, Енисея с притоками, р. Бирюсы и р. Лены (включая уровни воды заторного происхождения), и краткосрочных прогнозов ежедневных уровней воды рек Селенга и Онон: Отчет о НИР (закл.) / ФГБУ «СибНИГМИ»; шифр темы 1.7.49; рук. Д.А. Бураков. Новосибирск, 2013. 111 с. № ГР 01201178224. Инв. № 02201454632.
2. Бураков Д.А. Математическая модель расчета весеннего половодья для равнинных заболоченных бассейнов // Метеорология и гидрология. 1978. № 1. С. 49–59.
3. Бураков Д.А., Адамович А.А. Долгосрочные прогнозы притока воды в водохранилища Сибирских ГЭС с применением математической модели // Метеорология и гидрология. 2006. № 1. С. 95–105.
4. Бураков Д.А., Космакова В.Ф., Гордеев И.Н. Результаты испытания физико-статистического метода долгосрочного прогноза максимальных уровней воды весеннего половодья р. Енисей у г. Кызыл // Результаты испытания новых и усовершенствованных технологий, моделей и методов гидрометеорологических прогнозов. Информационный сборник № 39. 2012. С. 121–126.
5. Саноцкая Н.А., Лоскутов Д.А., Ромашова К.В. Прогнозирование максимального уровня воды рек как обобщенного параметра состояния сложной нелинейной системы на основе использования многослойной нейронной сети // Технологии гражданской безопасности. 2022. Т. 19, № 2 (72). С. 14–20.
6. Шолле Ф. Глубокое обучение на Python. 2-е межд. издание. СПб.: Питер, 2023. 576 с.