

УДК 551.482

РАЗРАБОТКА СПЕЦИАЛИЗИРОВАННОГО ПРОГРАММНОГО КОМПЛЕКСА ДЛЯ НЕЙРОСЕТЕВОГО ПРОГНОЗА ПАВОДКОВЫХ ВОД

Сырямкин Владимир Иванович¹,
svi_tsu@mail.ru

Иваненко Борис Павлович¹,
ivanenko_boris@mail.ru

Клестов Семён Александрович¹,
klestov_simon@mail.ru

Хильчук Мария Денисовна¹,
ma6a70@gmail.com

¹ Национальный исследовательский Томский государственный университет,
Россия, 634050, г. Томск, пр. Ленина, 36.

Актуальность исследования обусловлена необходимостью разработки современных методов оперативного мониторинга состояния территорий из-за наличия различного рода стихийных явлений, в частности наводнений и паводковых затоплений. Решению этой проблемы уделяется большое внимание государствами, регионами, муниципалитетами и поселениями.

Цель: разработка специализированного программного комплекса, предназначенного для решения задач краткосрочного и среднесрочного прогноза уровня паводковых вод на основе оперативных данных гидрологических наблюдений при минимальном наборе входных данных и с возможностью работать с данными аэрокосмических наблюдений.

Объекты: участок, на котором происходит слияние рек Томи и Оби и ниже по течению Оби в местах расположения гидрологических постов: пос. Победа, с. Никольское, с. Молчаново.

Методы: нейросетевое информационное моделирование.

Результаты. Рассмотрена методика создания нейросетевого имитатора, предназначенного для обработки результатов гидрологических измерений и решения широкого круга практических задач, в том числе и прогностических. Разработана оригинальная методика построения обучающих выборок, позволяющая получать результаты при минимальном наборе исходных данных. Исследована эффективность и точностные характеристики нейросетевых алгоритмов при решении задачи прогноза уровня паводковых вод в период с 1 апреля по 30 июня 2011–2017 гг.

Ключевые слова:

нейросетевое моделирование, прогноз, паводковые воды, численное моделирование, точностные характеристики, методика построения обучающих выборок.

Введение

Прогнозирование возможности возникновения опасных разливов на реках является сложной многоуровневой задачей, актуальность которой обусловлена состоянием современных хозяйственных систем, их уязвимостью. В зонах, подверженных негативному влиянию паводков и половодий находится большое количество населенных пунктов, критически важных и потенциально опасных объектов инфраструктуры, промышленных предприятий и сельскохозяйственных угодий [1–9].

При этом ущерб от наводнений зависит не только от уровня воды в водоемах и водотоках, а определяется в значительной степени предсказуемостью предстоящего половодья или паводка. Наличие заблаговременной и достаточно точной прогнозной информации позволяет рационально спланировать и провести превентивные мероприятия по недопущению либо минимизации ущерба от наводнений [9–16].

Чтобы смягчить последствия паводков и наводнений, в настоящее время актуальной становится задача разработки новых методов прогнозирования уровня паводковых вод. Одним из таких методов могут стать методы информационного моделирования, реализованные на нейросетевом базисе [17–21].

Следует отметить, что в настоящее время существуют и используются на практике различные методы решения поставленной задачи: статистические [22–24], регрессионные, иначе метод тенденций, метод соответственных уровней, метод соответственных объемов и т. д. Отметим, что использование этих методов требует привлечения значительных объемов априорной информации, а не только измерения уровней на пунктах наблюдений. Что касается нейросетевых методов прогноза уровня паводковых вод, то имеющийся ряд публикаций [3–9] не позволяет судить о точностных характеристиках используемых алгоритмов, а главное о составе и структуре обучающих выборок.

Известно, что в настоящее время основой использования технологии нейроинформатики в приложениях стало моделирование нейронных сетей на персональных компьютерах [25]. На данный момент существует несколько десятков коммерческих и свободно распространяемых программных нейроимитаторов.

Нейропакеты общего назначения являются наиболее распространенными. В нашей стране разработаны такие программы моделирования искусственных нейронных сетей (ИНС) универсального назначения, как NeuroPro красноярской группы «Нейрокомп»,

NeuroShell, Neural Bench. Из зарубежных наиболее известен продукт STATISTICA Neural Networks (SNN) фирмы StatSoft Inc [26].

Необходимо отметить, что они не обладают рядом возможностей для функционирования в составе информационных систем, состоящих из многих нейросетевых блоков, адаптивно настраивающихся и дообучающихся на вновь поступающих данных [27].

Инструменты для разработки нейросетевых приложений являются более сложными программными продуктами, предоставляющими разработчику разнообразные средства создания нейросетевых решателей. Главными отличительными чертами этого вида программных продуктов являются расширяемость, возможность создавать отторгаемые нейросетевые модули, которые могут быть использованы в составе любых систем обработки информации, возможность создавать комплексные нейросетевые системы для решения различных прикладных задач. В качестве примера можно привести пакет для построения моделей ИНС в среде MATLAB. Применение этих пакетов, как правило, требует навыков программирования и более глубокого знания методов нейронинформатики [28, 29].

Для построения нейронной сети, ориентированной на решение конкретной задачи, используются процедуры формирования (или создания) нейронных сетей. Эти процедуры обеспечивают ввод указанных характеристик моделей нейронов и структур нейронных сетей. Как правило, в каждой отдельной программе реализована лишь часть из описанных моделей нейронов и нейронных сетей. Каждая группа моделей нейронных сетей может быть использована для решения лишь некоторого ограниченного класса практических задач. Лишь для небольшого числа моделей нейронных сетей существует строгое математическое обоснование возможности их применения для решения конкретных практических задач. В наибольшей степени теоретически проработаны двухслойные нейронные сети с сигмоидальными передаточными функциями.

Общая методика разработки специализированных нейропакетов

Исходя из сказанного выше и опираясь на теорему Колмогорова–Арнольда [30, 31] о представлении непрерывных функций нескольких переменных в виде суперпозиции непрерывных функций одного переменного и переложенной Хехт–Нильсеном в термины теории нейронных сетей [32, 33], следует утверждение о том, что для представления нескольких переменных может быть использована двухслойная одно-родная нейронная сеть с сигмоидальными передаточными функциями. В связи со сказанным выше при разработке нейропакета мы на данном этапе исследования остановились на многослойном персептроне.

Обобщая наш опыт построения нейросетевых моделей, сформулируем методику нейросетевого моделирования и опишем её в стандарте IDEF0 [33–40]. На рис. 1 представлен процесс нейросетевого моделирования в виде «чёрного ящика».



Рис. 1. Процесс нейросетевого моделирования в виде «чёрного ящика»

Fig. 1. Neural network modeling in the form of a «black box»

Блок «Построение (коррекция) нейросетевой модели» (рис. 3) не отличается от общепринятых методик нейросетевого моделирования.

Наибольший интерес представляет декомпозиция блока «Построение обучающей выборки», представленная на рис. 4.

Необходимо дать следующие пояснения к диаграммам: на рис. 2–4 механизм исполнения некоторых процессов является «средство работы с ИНС». На этапе исследований это может быть любой нейронимитатор, однако на стадии промышленного использования это должен быть нейросетевой модуль, встроенный в специализированное программное обеспечение. Средство работы с данными может быть любым, начиная от универсальных, например, таких как Microsoft Excel, до узко специализированных. Особо отметим, что одним из важнейших этапов при разработке нейросетевых методов является исследование устойчивости и точностных характеристик. Устойчивость – одно из важнейших свойств, которым должна обладать модель. Под устойчивостью в данном случае будем понимать способность модели сохранять прогностические свойства на приемлемом уровне погрешностей измерений и при пропусках во входных данных. С этой целью рассматривается схема проведения численного замкнутого эксперимента при исследовании устойчивости и точностных характеристик нейросетевых алгоритмов. Данная схема представлена на рис. 5 в виде функциональной диаграммы описания процессов, выполненной по методологии IDEF0. К данной диаграмме необходимо дать следующие пояснения:

- Обучающая выборка, появляющаяся в результате работы процесса A3, строится на основе экспериментальных данных либо численного моделирования.
- В процессе A2 моделируется погрешность эксперимента. При этом в соответствующие поля обучающей выборки в период обучения вносится заданная случайная относительная погрешность. На период прогноза поля обучающей выборки не «зашумляются».

- В A5 на вход обученной нейронной сети подавались данные за весь исследуемый период (обучение–прогноз).
- В A6 рассчитывались соответствующие точностные характеристики, в качестве которых мы использовали: максимальное и среднее отклонение

решения от точного для периода обучения (погрешность обучения) и аналогичные характеристики для прогнозного периода (в нейросетевой терминологии – ошибки обобщения или в общепринятой терминологии – ошибки прогноза).

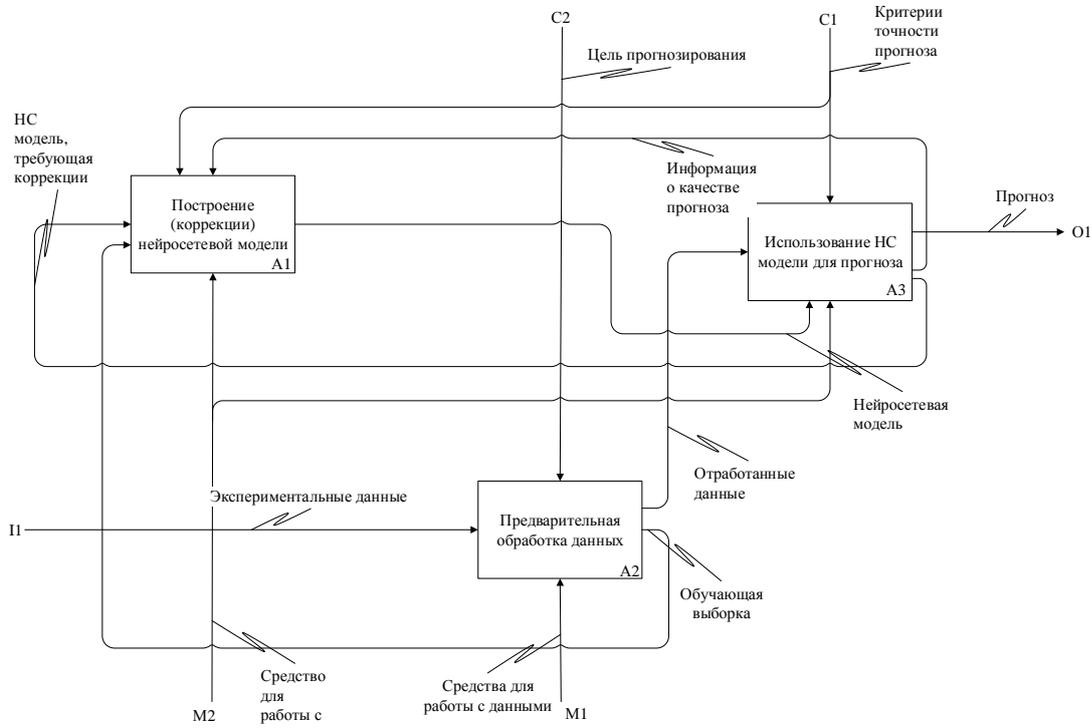


Рис. 2. Основные функциональные блоки нейросетевой модели и связи между ними
Fig. 2. The main functional blocks of the neural network model and connections between them

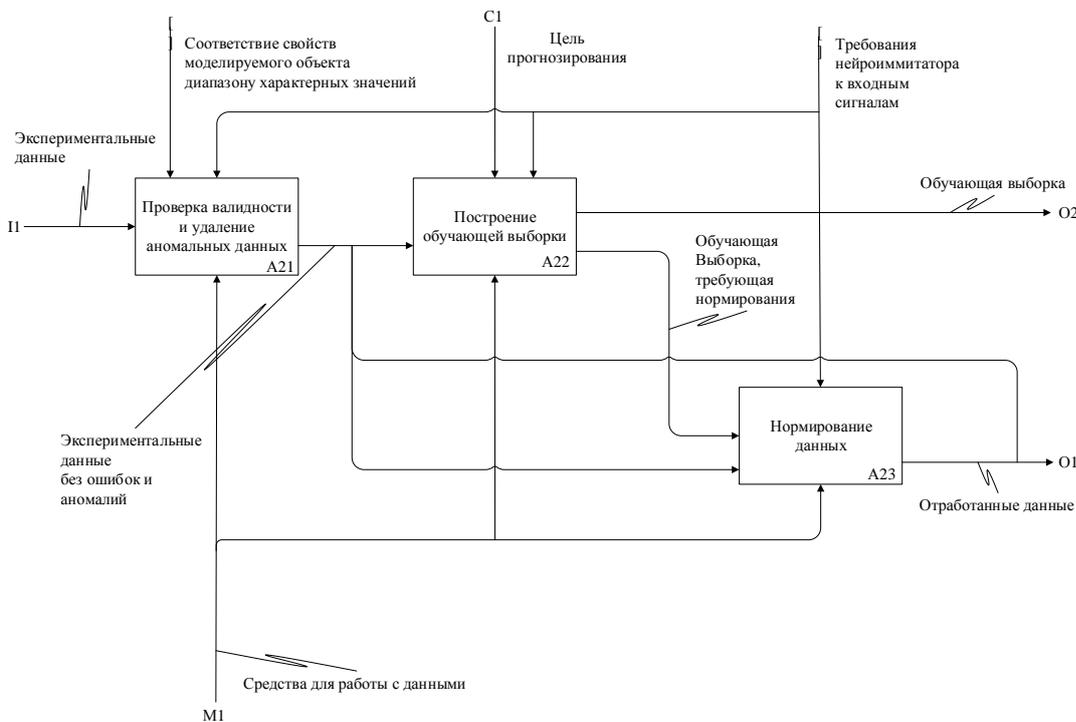


Рис. 3. Построение (коррекция) нейросетевой модели
Fig. 3. Construction (correction) of the neural network model

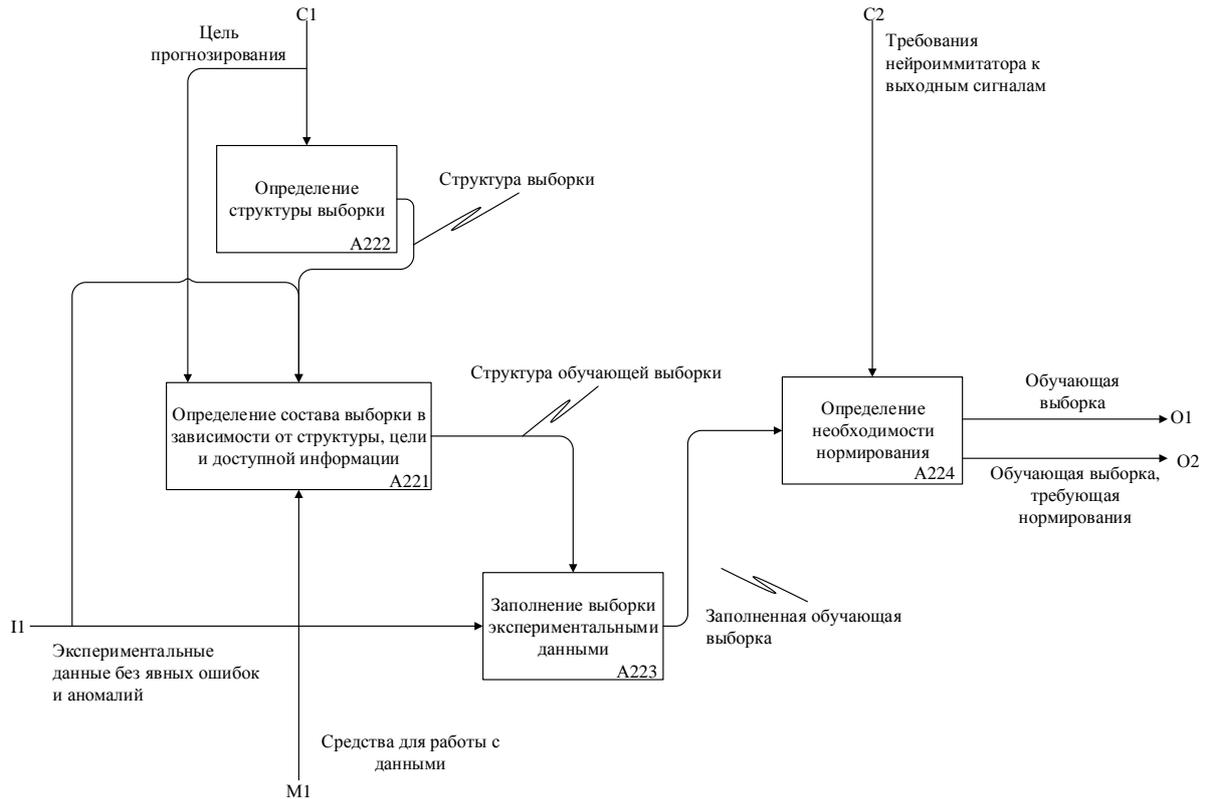


Рис. 4. Декомпозиция функционального блока «Построение обучающей выборки»

Fig. 4. Decomposition of the functional block «Construction of the training sample»

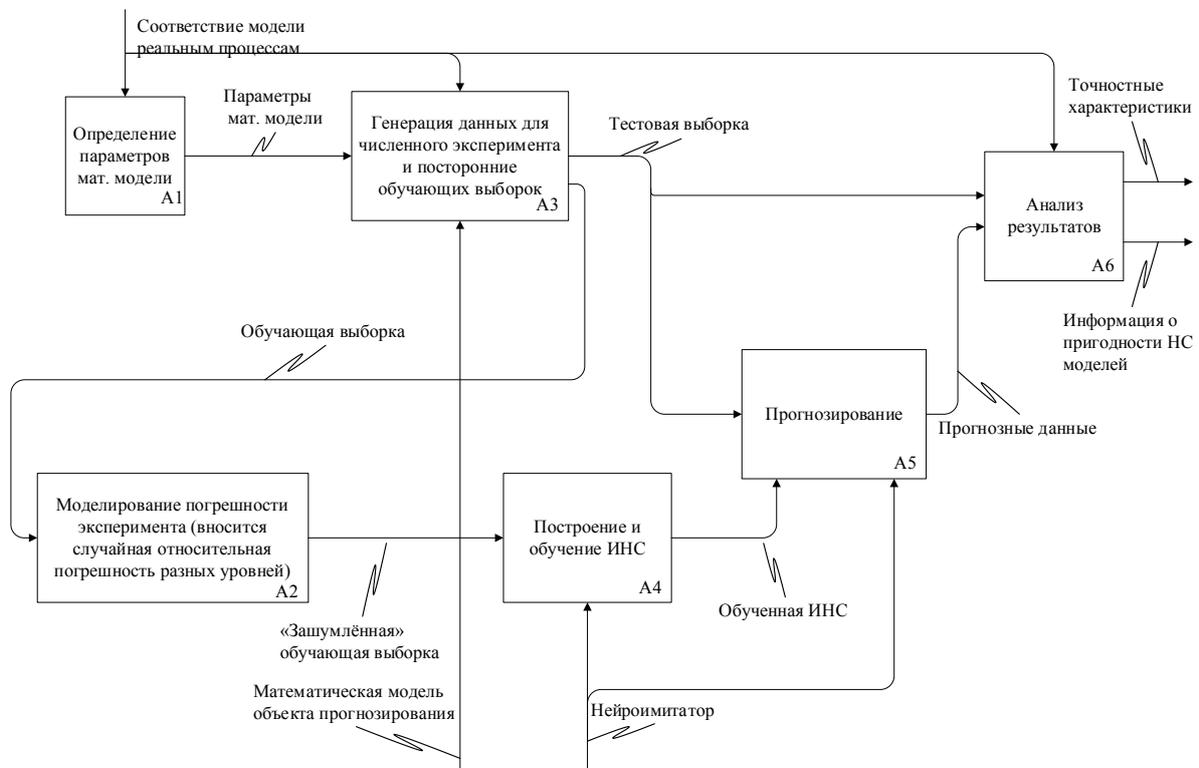


Рис. 5. Диаграмма процессов численного эксперимента, предназначенного для исследования эффективности нейросетевых методов

Fig. 5. Diagram of the processes of a numerical experiment designed to study the effectiveness of neural network methods

Далее приводится описание разрабатываемого нейросетевого программного комплекса (ПК) «NNet», предназначенного для решения задач прогноза паводковых вод. В отличие от описанных выше серийных ПК он должен обеспечивать следующие возможности:

- надежное функционирование в составе информационной системы (ИС) или системы управления;
- автоматизированная обработка данных с минимальным участием пользователя;
- интерфейсная часть нейросетевого модуля, рассчитанная на пользователя, не имеющего специальную подготовку;
- автоматизация построения, обучения и подбора архитектуры нейронной сети;
- автоматизация извлечения знаний из баз данных, отчетов, хранилищ экспериментальной информации;
- периодическое дообучение нейросетевой модели и корректировка архитектуры сети;
- генерация результатов в форматах, пригодных для обобщения и анализа стандартными средствами, использующимися в рентгеноструктурном анализе.

Разрабатываемый ПК «NNet» ориентирован на работу в x86-64 совместимых платформах, что даёт возможность осуществлять взаимодействие пользователя с программой на основе многооконного диалогового интерфейса с развитой системой помощи, соответствующей требованиям GUI (Graphic User Interface) среды Windows, учитывая ресурсоёмкость нейровычислений. Программная реализация данного пакета осуществлена при помощи языка программирования C++. От приложений, основанных на ИНС, требуется значительное быстродействие, особенно на этапе обучения сети, и чем ниже уровень, на котором ведётся разработка, тем обычно выше быстродействие.

В основе разработанного программного средства лежит модель многокомпонентных объектов COM (Component Object Model). COM – это метод разработки программных компонентов, небольших двоичных исполняемых файлов, которые предоставляют необходимые сервисы приложениям, операционным системам и другим компонентам. Компоненты COM объединяются друг с другом для создания приложений или систем компонентов. Компоненты можно отключать и менять во время выполнения без перекомпиляции или перекомпоновки приложения. COM является ядром технологий объектного программирования фирмы Microsoft, известных под названиями OLE, ActiveX, DirectX. COM определяет, каким образом объект (он же компонент, он же сервер) предоставляет свою функциональность использующему его клиенту, как эта функциональность передаётся между процессами и компьютерами, как объекты создаются и уничтожаются и как они идентифицируют себя.

Более подробно о технологии COM можно узнать в работах [41–43], а мы лишь ограничимся перечислением преимуществ технологии COM:

- Полностью независимы от языка программирования. Они могут быть разработаны с помощью

практически любого процедурного языка, включая C, Java, Python. Любой язык, в том числе Visual Basic, можно приспособить к использованию компонентов COM. Можно написать компоненты COM, используемые из языков макрокоманд (например, VB script или Visual Basic for Application).

- Могут распространяться в двоичной форме.
- Могут быть модернизированы без нарушения работы старых клиентов.
- Могут прозрачно перемещаться по сети. Компонент на удалённой системе рассматривается клиентом так же, как компонент на локальном компьютере.

Каждый объект предоставляет свою функциональность через *интерфейсы*, которые являются заранее определённым и неизменным набором методов. Клиент может обратиться к объекту только через реализуемые им интерфейсы – доступа к данным объекта у него нет. Интерфейс, определённый однажды, нельзя изменить. Если нужно пополнить или исправить интерфейс, то следует определить новый интерфейс, возможно, на базе старого.

Для сокращения времени разработки и улучшения качества разрабатываемого программного обеспечения использовалась ATL (Active Template Library) – библиотека шаблонов классов C++, позволяющая создавать COM-объекты и содержащая базовые классы, реализующие функциональность, а также классы, реализующие основные интерфейсы OLE и ActiveX.

Разрабатываемые нейросетевые компоненты NetCore и NNetAx позволяют решать следующие задачи:

- Создавать ИНС слоистой архитектуры без обратных связей с любым количеством слоёв любой размерности.
- Выбирать функцию активации для каждого слоя из нижеперечисленных: линейная функция, функция Ферми, рациональная сигмоида, гиперболический тангенс.
- Просматривать весовые матрицы каждого слоя и редактировать весовые коэффициенты.
- Создавать выборки данных любой размерности, выделять в них учебное, проверочное и тестовое множества.
- Редактировать обучающие выборки, импортировать данные из других приложений посредством стандартных механизмов обмена данными.
- Нормировать данные в диапазон $(-1;1)$, пригодный к использованию в нейронных сетях.
- Обучать ИНС по алгоритму обратного распространения ошибки и его модификациям [43].
- Использовать момент обучения.
- Параметр обучения (шаг обучения) может подстраиваться случайным образом на каждой эпохе обучения.
- По окончании обучения восстановить значения весовых коэффициентов, при которых была достигнута минимальная ошибка обучения.
- Задать критерий остановки обучения по количеству эпох или по достижению заданной ошибки обучения.

- Добавлять нейроны в процессе обучения в любой слой (кроме выходного).
- Получать значения с выхода нейронной сети при подаче на её входы одного входного вектора из выборки из входных векторов, сохранённой в файле.
- В отличие от стандартных нейропакетов производится импорт данных следующего формата: цифровые изображения (.png, .tiff) и текстовые файлы описания (.txt, .json), что позволяет работать с данными аэрофотосъёмок.
- Экспортировать результаты работы ИНС в распространённые форматы хранения информации.

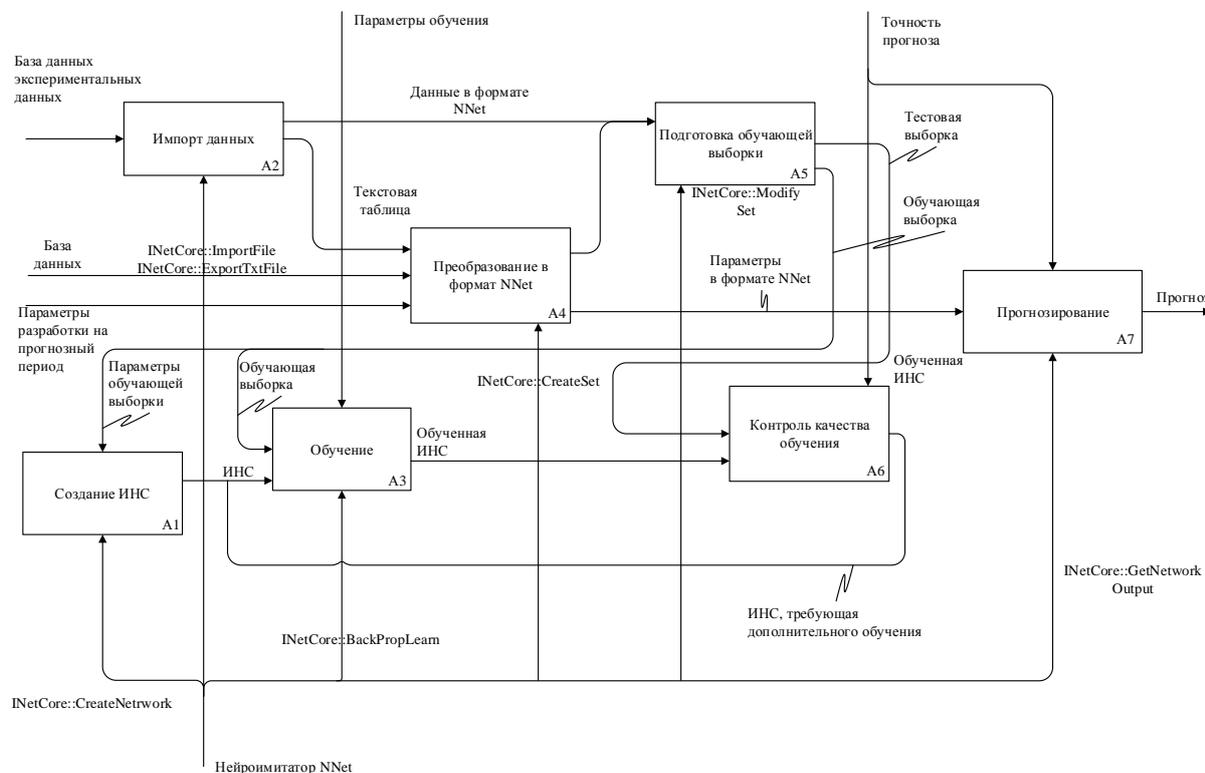


Рис. 6. Диаграмма процессов нейромиматора «NNet»
 Fig. 6. Diagram of the processes of the neurosimulator «NNet»

Практические результаты

Прежде чем перейти к содержательной части, напомним, что нейросетевая постановка задачи, как правило, состоит из нескольких этапов:

Первый этап – физическая постановка задачи с целью построения обучающих выборок. Цель – решение задачи краткосрочного и среднесрочного прогноза уровня паводковых вод на основе наблюдений на гидропостах при минимальном наборе входных данных.

Второй этап – предобработка исходных данных. Отметим, что в данном случае погрешность измерений уровней не превышает 2–3 см (порядка 1 %) и предобработка данных измерений сводится к поиску очевидных случайных выбросов и восстановлению пробелов в базах данных. Однако при расширении состава обучающей выборки, например, толщины снегового покрова, объемов сброса с Новосибирского водохранилища, ледовой обстановки, притока талых вод и т. д., предобработка исходных данных станет необходимой.

Третий этап – построение обучающих выборок. Основой для построения обучающих выборок служи-

ли имеющиеся в нашем распоряжении измеренные среднесуточные уровни воды на реке Оби в период с 01.04 по 30.07 за 8 лет с 2011 по 2018 гг. в следующих створах: р. Обь – п. Победа, р. Обь – п. Никольское, р. Обь – п. Молчаново (рис. 7).

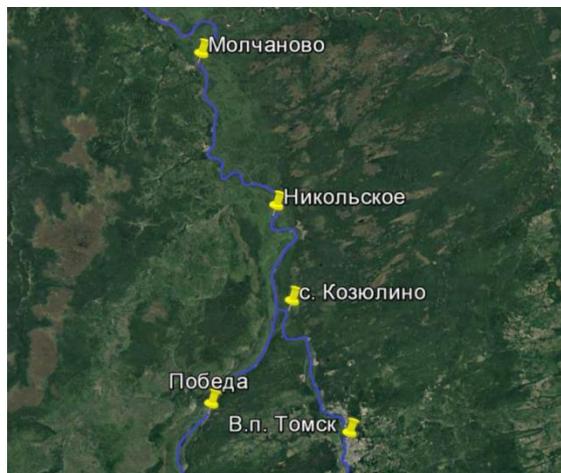


Рис. 7. Расположение постов
 Fig. 7. Location of posts

На рис. 7 приведены результаты наблюдений за уровнем паводковых вод в 2014 г.

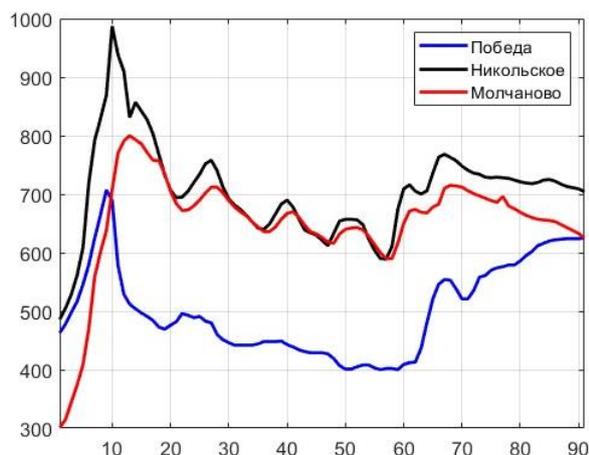


Рис. 8. Уровень паводковых вод по данным ежесуточных наблюдений для периода с 1 апреля по 1 июня 2014 г.

Fig. 8. Flood water level according to daily observations for the period from April 1 to June 1, 2014

Четвертый этап – выбор архитектуры сети и алгоритма ее обучения. В данном случае при решении задачи прогноза использовался многослойный перцептрон с обучением по методу обратного распространения ошибки.

Пятый этап – получение и анализ результатов. На рис. 9, 10 приведены результаты прогноза уровня паводковых вод для п. Молчаново на 2018 г. Здесь по оси ординат нанесены значения уровней паводковых вод в период половодья, а по оси абсцисс – даты наблюдений. При обучении сети использовались лишь данные ежедневных наблюдений за 2011, 2013, 2014, 2015, 2016 и 2017 гг., всего 480 наблюдений за вычетом 60 верификационных примеров, которые выбирались случайным образом. Отметим, что из обучающей выборки исключались данные измерений в 2012 г., т. к. в этом году наблюдался чрезвычайно низкий уровень паводковых вод, что нарушает однородность обучающей выборки. Очевидно, что увеличение размера обучающей выборки позволит снять эту проблему. Что касается полученных результатов, то не вызывает сомнений, что в данном случае полученный результат отрицательный.

В данном случае в состав обучающей выборки входили: года наблюдений (с 2011 по 2017), даты наблюдений для каждого года (с 1 апреля по 1 июня – всего 90 дней), даты наблюдений за весь период наблюдений (всего 540 дней), средние (по годам) значения уровней, отклонение от среднего. Особо отметим, что параметрами обучения в данном случае служили значения уровней и их отклонение от среднего. Полученные результаты показали эффективность предложенного метода построения обучающей выборки с учетом использования дополнительной априорной информации. При этом максимальная ошибка прогноза не превышает 10 см, средняя погрешность равна 0,75 см, а абсолютная средняя ошибка – 2–42 см.

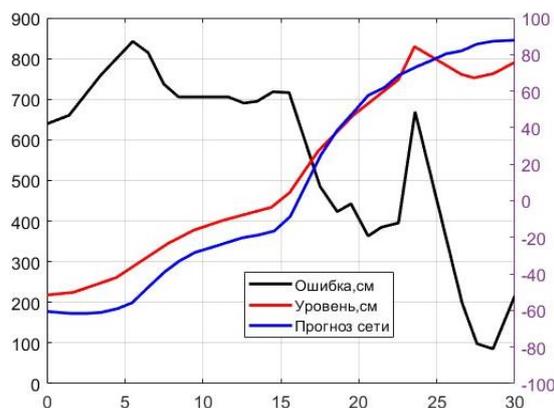


Рис. 9. Результаты прогноза уровня паводковых вод для п. Молчаново (без учета априорной информации)

Fig. 9. Results of forecasting the level of flood waters for Molchanovo (excluding a priori information)

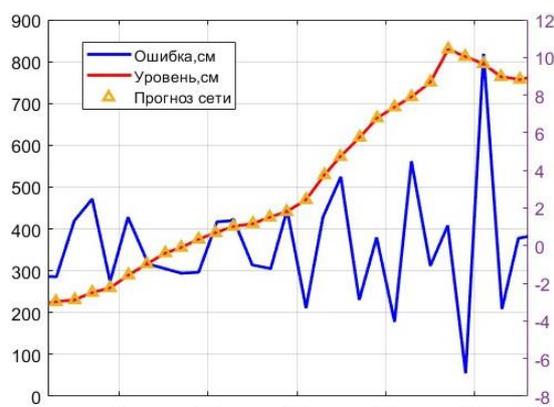


Рис. 10. Результаты прогноза уровня паводковых вод для п. Молчаново (с использованием априорной информации)

Fig. 10. Results of forecasting the level of flood waters for Molchanovo (using a priori information)

В Томском государственном университете разработали геоинформационную систему (ГИС), позволяющую в онлайн режиме отслеживать процесс затопления прибрежных населенных пунктов и детально показывать его на картах местности вплоть до домов и улиц. Точность прогноза составляет 10–15 см, что является приемлемым в рамках задачи прогнозирования [22].

В заключение на конкретном примере еще раз рассмотрим вопрос предварительной обработки данных измерений, так как любые экспериментальные данные всегда содержат случайную погрешность, что требует использовать соответствующие методы фильтрации. Отметим, что возможность борьбы со случайными погрешностями измерений заложена в самих нейросетях [34–37], т. е. в их регуляризирующих свойствах.

В приложении к нейросетевым моделям регуляризирующие методы сводятся к оптимизации функционала ошибки (в простейшем случае – суммы квадратов отклонений модели от экспериментальных значений) с аддитивной добавкой, исчезающей по мере улучшения свойств гладкости функции:

$$E[G] = \sum_{\alpha=1}^{N_{\alpha}} (G(\bar{x}^{\alpha}) - \bar{y}^{\alpha})^2 + \lambda \varphi[G].$$

Здесь φ – регуляризирующий функционал, λ – параметр регуляризации.

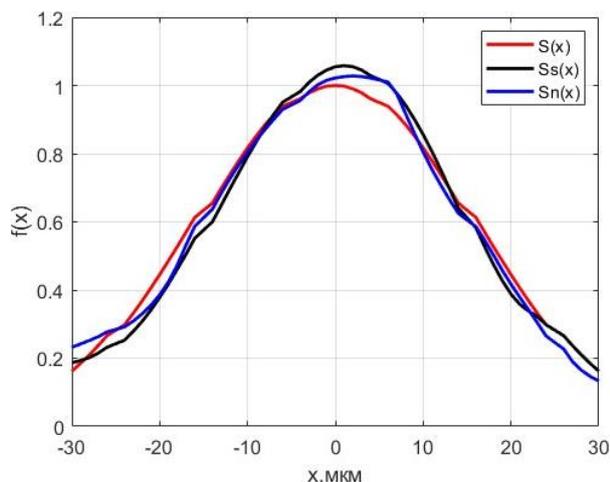


Рис. 11. Пример сигнала, восстановленного на фоне случайных помех

Fig. 11. Example of a signal restored against the background of random noise

В качестве примера приведем результаты восстановления сильно зашумленного сигнала, полученного на рентгеновском томографе (рис. 11). Здесь $S_d(x)$ представляет собой сумму полезного сигнала и шума, $S(X)$ – регуляризованные, восстановленные

нейросетью, $SS(X)$ – точные значения. Выбор данного примера показывает универсальный характер разрабатываемого программного комплекса.

Заключение

Описана схема создания нейросетевого имитатора как программного пакета, предназначенного для интеграции в информационные системы, системы управления, а также в специализированное программное обеспечение для обработки результатов измерений и решения широкого круга практических задач. Описаны процессы моделирования с нейросетевым имитатором, функциональные блоки самой нейросетевой модели, а также связи между ними, процесс создания обучающей выборки данных с разделением ее на подмножества: обучающее, верификационное, прогнозное. Представлена полная диаграмма разрабатываемого нейроимитатора «NNet» с описанием его свойств. Отметим, что в нем предусмотрен отдельный модуль, предназначенный для проведения замкнутого численного эксперимента, для исследования эффективности и точностных характеристик нейросетевых методов, а также имеется возможность работать с данными аэрокосмических наблюдений. Предложен оригинальный метод построения обучающей выборки, позволивший решить задачу среднесрочного прогноза паводковых вод в период весеннего половодья с точностью порядка 10 см при минимальном наборе исходных данных.

Исследование выполнено за счет гранта Российского научного фонда № 22-19-00389, <https://rscf.ru/project/22-19-00389/>.

СПИСОК ЛИТЕРАТУРЫ

1. Abdulhakim F., Jun F. Prediction of flow flooding in Changhua river based on Time Series Models // 2019 IEEE 4th Advanced Information Technology, Electronic and Automation Control Conference (IAEAC). – Chengdu, China, 2019. – V. 1. – P. 1663–1669.
2. Dampage U. et al. Artificial neural network for forecasting of daily reservoir inflow: case study of the Kotmale reservoir in Sri Lanka // 2020 5th International Conference on Computational Intelligence and Applications (ICCIA). – Haikou, China, 2020. – P. 8–12.
3. Nazari L.F., Camponogara E., Seman L.O. Physics-informed neural networks for modeling water flows in a river channel // IEEE Transactions on Artificial Intelligence. – Australia, University of New South Wales, 2022. – P. 1–15.
4. Zhou Y. et al. Improving the reliability of probabilistic multi-step-ahead flood forecasting by fusing unscented Kalman filter with recurrent neural network // Water. – 2020. – V. 12. – № 2. – P. 578–593.
5. Zainorzuli S.M. et al. Comparative study of Elman Neural Network (ENN) and neural network autoregressive with exogenous input (NARX) for flood forecasting // 2019 IEEE 9th Symposium on Computer Applications & Industrial Electronics (ISCAIE). – Kota Kinabalu, Sabah, Malaysia, 2019. – P. 11–15.
6. Liu J., Feng S. Intelligent forecasting model for hydrological and water resources system // 2019 11th International Conference on Measuring Technology and Mechatronics Automation (ICMTMA). – Qiqihar, China, 2019. – P. 657–661.
7. Zhu C., Ma X. Simulation of flood water level using PSO-based RBF neural network // 2009 Third International Symposium on Intelligent Information Technology Application. – Nanchang, China, 2009. – V. 1. – P. 68–71.
8. Jhong Y.D. et al. Physical hybrid neural network model to forecast typhoon floods // Water. – 2018. – V. 10. – № 5. – P. 632–649.
9. Tiwari M.K., Chatterjee C. Uncertainty assessment and ensemble flood forecasting using bootstrap based artificial neural networks (BANNs) // Journal of Hydrology. – 2010. – V. 382. – № 1–4. – С. 20–33.

10. Yan J. et al. RBF model applied to forecast the water and sediment fluxes in Lijin section // 2009 2nd International Congress on Image and Signal Processing. – Tianjin, China, 2009. – P. 1–5.
11. Yuan W.Z., Ya W.X. The BP neural network prediction rudder fall mouth water level and optimization of array parameters // Proceedings of 2012 2nd International Conference on Computer Science and Network Technology. – Changchun, China, 2012. – P. 1386–1390.
12. Cannas B. et al. Neural network models to forecast hydrological risk // Proceedings of the 2002 International Joint Conference on Neural Networks. IJCNN'02 (Cat. No. 02CH37290). – Honolulu, Hawaii, 2002. – V. 1. – P. 423–426.
13. Xinhua C., Zhuying L. The application of neural network technology in floodwater forecast // 2010 International Conference on Networking and Digital Society. – Wenzhou, China, 2010. – V. 2. – P. 419–421.
14. Chaowanawatee K., Heednacram A. Implementation of cuckoo search in RBF neural network for flood forecasting // 2012 fourth international conference on computational intelligence, communication systems and networks. – Phuket, Thailand, 2012. – P. 22–26.
15. Chang F.J. et al. Real-time multi-step-ahead water level forecasting by recurrent neural networks for urban flood control // Journal of Hydrology. – 2014. – V. 517. – P. 836–846.
16. Darras T. et al. Neural network modeling and geochemical water analyses to understand and forecast karst and non-karst part of flash floods (case study on the Lez River, Southern France) // Proceedings of the International Association of Hydrological Sciences. – 2015. – V. 369. – P. 43–48.
17. Шамсутдинова Т.М. Проблемы нейросетевого и регрессионного прогнозирования уровня паводка рек // Сибирский пожарно-спасательный вестник. – 2021. – № 2 (21). – С. 99–105. DOI: 10.34987/vestnik.sibpsa.2021.79.13.017.
18. Использование нейросетевых программ для целей прогнозирования (на примере затопления территории Красноярского

- края) / А.К. Москалев, М.Н. Насухин, В.С. Луценко и др. // Экономика и предпринимательство. – 2020. – № 1 (114). – С. 1218–1223.
19. Обзор методов эффективного прогнозирования характеристик речного стока в горных и полугорных районах / Е.В. Гайдукова, В.Г. Маргарян, Н.В. Якишева и др. // Евразийское Научное Объединение. – 2021. – № 7-4 (77). – С. 324–330. DOI: 10.5281/zenodo.5168514.
20. Ямашкин С.А., Ямашкин А.А., Ямашкина Е.О. Проектно-ориентированные геопортальные системы в решении задачи прогнозирования уровней воды в период весеннего половодья // Современные наукоемкие технологии. – 2021. – № 11-1. – С. 75–81. DOI: 10.17513/snt.38891.
21. Нейросетевое моделирование эффективности реагирования на чрезвычайные ситуации в многоуровневой системе управления / Н.Г. Топольский, С.Ю. Бутузов, В.Я. Вилисов, В.Л. Семиков // Технологии техносферной безопасности. – 2021. – № 2 (92). – С. 79–93. DOI: 10.25257/TTS.2021.2.92.79-93.
22. Компьютерное моделирование в онлайн-режиме процесса затопления населенного пункта и поиск наилучших маршрутов для эвакуации населения (на примере деревни Черная речка Томской области) / В.В. Хромых, Д. Накаяма, О.В. Хромых, Е.В. Егорова // Геоморфология и физическая география Сибири в XXI веке: Материалы Всероссийской научно-практической конференции, посвященной 100-летию со дня рождения заслуженного работника высшей школы Российской Федерации, почетного члена Русского географического общества, профессора, доктора географических наук Земцова Алексея Анисимовича. – Томск: Изд-во Том. ун-та, 2020. – С. 209–213.
23. Чеботарев А.И. Гидрологический словарь. – Л.: Гидрометеоиздат, 1978. – 308 с.
24. Бубин М.Н. Прогнозирование паводков летне-осеннего периода // Успехи современного естествознания. – 2014. – № 12-5. – С. 550–553.
25. Горбань А.Н., Россиев Д.А. Нейронные сети на персональном компьютере. – Новосибирск: Наука, 1996. – 276 с.
26. Царегородцев В.Г. Нейроимитатор NEUROPRO // Нейроинформатика и ее приложения: Тез. докл. VI Всероссийского семинара / под ред. А.Н. Горбаня. – Красноярск: КГТУ, 2–5 октября 1998. – С. 207–208.
27. Управление рисками наводнений как составляющая часть интеллектуальной многомерной системы мониторинга территорий / А.Н. Берцун, Б.П. Иваненко, С.А. Клестов, В.И. Сырямкин // Инноватика-2021: сборник материалов XVII Международной школы-конференции студентов, аспирантов и молодых ученых. – Томск, 22–23 апреля 2021. – Томск: Общество с ограниченной ответственностью «СТТ», 2021. – С. 93–95.
28. Топольский Н.Г., Вилисов В.Я. Методы, модели и алгоритмы в системах безопасности: машинное обучение, робототехника, страхование, риски, контроль. – М.: ООО ИЦ «РИОР», 2021. – 475 с. DOI: 10.29039/02072-2.
29. Виноградов О.В., Морозова О.А. Аспекты применения нейронных сетей для прогнозирования чрезвычайных ситуаций // Технологии гражданской безопасности. – 2021. – Т. 18. – № 1 (67). – С. 23–26. DOI: 10.54234/CST.19968493.2021.18.1.67.4.23.
30. Колмогоров А.Н. О представлении непрерывных функций нескольких переменных суперпозициями непрерывных функций меньшего числа переменных // Докл. АН СССР. – 1956. – Т. 108. – № 2. – С. 179–182.
31. Колмогоров А.Н. О представлении непрерывных функций нескольких переменных в виде суперпозиции непрерывных функций одного переменного // Докл. АН СССР. – 1957. – Т. 114. – № 5. – С. 953–956.
32. Hecht-Nielsen R. Neurocomputing: picking the human brain // IEEE Spectrum, 1988, March. – P. 36–41.
33. Hecht-Nielsen R. Theory of the backpropagation neural network // Neural Networks for Human and Machine Perception / Ed. by H. Wechsler. – Boston, MA: Academic Press, 1992. – V. 2. – P. 65–93.
34. Иваненко Б.П. Нейросетевое имитационное моделирование нефтяных месторождений и гидрогеологических объектов. – Томск: ИД Томского Госуниверситета, 2014. – 186 с.
35. Иваненко Б.П., Клестов С.А., Сырямкин В.И. Нейросетевой прогноз природных ресурсов. На примере реальных нефтяных месторождений, полигонов захоронения ЖРО, прогнозе паводковых вод. – Лондон: Изд-во «LAP LAMBERT», 2019. – 190 с.
36. Сырямкин В.И., Шумилов В.Н. Синтез искусственного носителя интеллекта: информационно-биологический подход. 4-е изд., перераб. и доп. – М.; Берлин: ООО «Директ-Медиа», 2021. – 228 с.
37. Syryamkin V.I., Gorbachev S.V., Shikhman M.V. Adaptive fuzzy neural production network with MIMO-structure for the evaluation of technology efficiency // IOP Conference Series: Materials Science and Engineering. – Tomsk, 22–24 November 2018. – Tomsk: Institute of Physics Publishing, 2019. – P. 012010. DOI: 10.1088/1757-899X/516/1/012010.
38. Syryamkin V.I., Gorbachev S.V., Shikhman M.V. Adaptive neuro-fuzzy classifier for evaluating the technology effectiveness based on the modified Wang and Mendel fuzzy neural production MIMO-network // IOP Conference Series: Materials Science and Engineering. – Tomsk, 22–24 November 2018. – Tomsk: Institute of Physics Publishing, 2019. – P. 012037. DOI: 10.1088/1757-899X/516/1/012037.
39. Горбачев С.В., Сырямкин В.И., Абрамова Т.В. Метод синтеза нейро-нечеткого классификатора на основе дерева решений // Телекоммуникации. – 2018. – № 9. – С. 2–7.
40. Интеллектуальные распределенные системы распознавания образов в комплексах мониторинга, прогноза, диагностики, управления и обеспечения безопасности / В.И. Сырямкин, С.Б. Сунцов, В.С. Титов и др. // Оптико-электронные приборы и устройства в системах распознавания образов, обработки изображений и символической информации. Распознавание-2017: сборник материалов XIII Международной научно-технической конференции. – Курск, 16–19 мая 2017. – Курск: Юго-Западный государственный университет, 2017. – С. 336–341.
41. Роджерсон Д. Основы СОМ / пер. с англ. 2-е изд. – М.: Издательско-торговый дом «Русская редакция», 2000. – 400 с.
42. Трельсен Э. Модель СОМ и применение АТЛ 3.0 / пер. с англ. – СПб.: BHV–Санкт-Петербург, 2000. – 928 с.
43. Горбань А.Н. Быстрое дифференцирование, двойственность и обратное распространение ошибки // Нейроинформатика. – Новосибирск: Наука, Сибирская издательская фирма РАН, 1998. – 337 с.

Поступила: 24.09.2022 г.

Прошла рецензирование: 08.01.2023 г.

Информация об авторах

Сырямкин В.И., доктор технических наук, профессор, Заслуженный изобретатель Российской Федерации, Заслуженный работник Высшей школы РФ, Лауреат Премии Правительства РФ в области образования, заведующий кафедрой управления качеством факультета инновационных технологий Национального исследовательского Томского государственного университета.

Иваненко Б.П., кандидат физико-математических наук, старший научный сотрудник Международной лаборатории Систем технического зрения Национального исследовательского Томского государственного университета.

Клестов С.А., ассистент кафедры управления качеством факультета инновационных технологий Национального исследовательского Томского государственного университета.

Хильчук М.Д., инженер Международной лаборатории Систем технического зрения Национального исследовательского Томского государственного университета.

UDC 551.482

DEVELOPMENT OF A SPECIALIZED SOFTWARE PACKAGE FOR NETWORK FORECAST OF FLOOD WATERS

Vladimir I. Sryamkin¹,
svi_tsu@mail.ru

Boris P. Ivanenko¹,
ivanenko_boris@mail.ru

Semen A. Klestov¹,
klestov_simon@mail.ru

Maria D. Khilchuk¹,
ma6a70@gmail.com

¹ National Research Tomsk State University,
36, Lenin avenue, Tomsk, 634050, Russia.

The relevance of the study is caused by the need to develop modern methods of operational monitoring of the condition of territories due to the presence of various kinds of natural phenomena, in particular, floods and flood inundations. A lot of attention is paid to solving this problem by States, regions, municipalities and settlements.

Purpose: development of a specialized software package designed to solve problems of short-term and medium-term flood water level forecasting based on operational data from hydrological observations with a minimum set of input data and with the ability to work with aerospace observation data.

Objects: the area where the Tom and Ob rivers merge and downstream of the Ob river at the locations of hydrological posts: villages Pobeda, Nikolskoye, Molchanovo.

Methods: neural network information modeling.

Results. The paper considers the method of creating a neural network simulator designed for processing the results of hydrological measurements and solving a wide range of practical problems, including prognostic ones. An original method of constructing training samples was developed, which allows obtaining results with a minimum set of initial data. The authors investigated the efficiency and accuracy characteristics of neural network algorithms in solving the problem of forecasting the flood water level in the period from April 1 to June 30, 2011–2017.

Key words:

neural network modeling, forecast, flood waters, numerical modeling, accuracy characteristics, methods of constructing training samples.

The research was funded with the grant of the Russian Science Foundation no. 22-19-00389, <https://rscf.ru/project/22-19-00389/>.

REFERENCES

- Abdulkhakim F., Jun F. Prediction of flow flooding in Changhua river based on Time Series Models. *2019 IEEE 4th Advanced Information Technology, Electronic and Automation Control Conference (IAEAC)*. Chengdu, China, 2019. Vol. 1, pp. 1663–1669.
- Dampage U. Artificial neural network for forecasting of daily reservoir inflow: case study of the kotmale reservoir in Sri Lanka. *2020 5th International Conference on Computational Intelligence and Applications (ICCIA)*. Haikou, China, 2020. pp. 8–12.
- Nazari L.F., Camponogara E., Seman L.O. Physics-informed neural networks for modeling water flows in a river channel. *IEEE Transactions on Artificial Intelligence*. Australia, University of New South Wales, 2022. pp. 1–15.
- Zhou Y. Improving the reliability of probabilistic multi-step-ahead flood forecasting by fusing unscented Kalman filter with recurrent neural network. *Water*, 2020, vol. 12, no. 2, pp. 578–593.
- Zainorzuli S.M. Comparative study of Elman Neural Network (ENN) and neural network autoregressive with exogenous input (NARX) for flood forecasting. *2019 IEEE 9th Symposium on Computer Applications & Industrial Electronics (ISCAIE)*. Kota Kinabalu, Sabah, Malaysia, 2019. pp. 11–15.
- Liu J., Feng S. Intelligent forecasting model for hydrological and water resources system. *2019 11th International Conference on Measuring Technology & Mechatronics Automation (ICMTMA)*. Qiqihar, China, 2019. pp. 657–661.
- Zhu C., Ma X. Simulation of flood water level using PSO-based RBF neural network. *2009 Third International Symposium on Intelligent Information Technology Application*. Nanchang, China, 2009. Vol. 1, pp. 68–71.
- Jhong Y.D. Physical hybrid neural network model to forecast typhoon floods. *Water*, 2018, vol. 10, no. 5, pp. 632–649.
- Tiwari M.K., Chatterjee C. Uncertain assessment and ensemble flood forecasting using bootstrap based artificial neural networks (BANNs). *Journal of Hydrology*, 2010, vol. 382, no. 1–4, pp. 20–33.
- Yan J. RBF model applied to forecast the water and sediment fluxes in Lijin section. *2009 2nd International Congress on Image and Signal Processing*. Tianjin, China, 2009. pp. 1–5.
- Yuan W.Z., Ya W.X. The BP neural network prediction rudder fall mouth water level and optimization of array parameters. *Proceedings of 2012 2nd International Conference on Computer Science and Network Technology*. Changchun, China, 2012. pp. 1386–1390.
- Cannas B. Neural network models to forecast hydrological risk. *Proceedings of the 2002 International Joint Conference on Neural Networks. IJCNN'02 (Cat. No. 02CH37290)*. Honolulu, Hawaii, 2002. Vol. 1, pp. 423–426.
- Xinhua C., Zhuying L. The application of neural network technology in floodwater forecast. *2010 International Conference on Networking and Digital Society*. Wenzhou, China, 2010. Vol. 2, pp. 419–421.
- Chaowanawatee K., Heednacram A. Implementation of cuckoo search in RBF neural network for flood forecasting. *2012 fourth international conference on computational intelligence, communication systems and networks*. Phuket, Thailand, 2012. pp. 22–26.
- Chang F.J. Real-time multi-step-ahead water level forecasting by recurrent neural networks for urban flood control. *Journal of Hydrology*, 2014, vol. 517, pp. 836–846.

16. Darras T. Neural network modeling and geochemical water analyzes to understand and forecast karst and non-karst part of flash floods (case study on the Lez river, Southern France). *Proceedings of the International Association of Hydrological Sciences*, 2015, vol. 369, pp. 43–48.
17. Shamsutdinova T.M. Problems of neural network and regression forecasting of river flood levels. *Siberian Fire and Rescue Bulletin*, 2021, no. 2 (21), pp. 99–105. In Rus. DOI: 10.34987/vestnik.sibpsa.2021.79.13.017.
18. Moskalev A.K., Nasukhin M.N., Lutsenko V.S. The use of neural network programs for forecasting purposes (on the example of flooding of the territory of the Krasnoyarsk Territory). *Economics and Entrepreneurship*, 2020, no. 1 (114), pp. 1218–1223. In Rus.
19. Gaydukova E.V., Margaryan V.G., Myakisheva N.V. Review of methods for effective forecasting of river runoff characteristics in mountainous and semi-mountainous regions. *Eurasian Scientific Association*, 2021, no. 7-4 (77), pp. 324–330. In Rus. DOI: 10.5281/zenodo.5168514
20. Yamashkin S.A., Yamashkin A.A., Yamashkina E.O. Project-oriented geoport systems in solving the problem of forecasting water levels during the spring flood. *Modern science-intensive technologies*, 2021, no. 11-1, pp. 75–81. DOI: 10.17513/snt.38891.
21. Topolsky N.G., Butuzov S.Yu., Vilisov V.Ya., Semikov V.L. Neural network modeling of the effectiveness of response to emergency situations in a multilevel control system. *Technologies of technosphere safety*, 2021, no. 2 (92), pp. 79–93. In Rus. DOI: 10.25257/TTS.2021.2.92.79-93.
22. Khromykh V.V., Nakayama D., Khromykh O.V., Egorova E.V. Kompyuternoe modelirovanie v onlain rezhime protsessa zatopeniya naselennogo punkta i poisk nailuchshikh marshrutov dlya evakuatsii naseleniya (na primere derevni Chernaya rechka Tomskoy oblasti) [Computer modeling in online mode of flooding a settlement and the search for the best routes for the evacuation of the population (on the example of the village of Chernaya Rechka, Tomsk Region)]. *Geomorfologiya i fizicheskaya geografiya Sibiri v XXI veke. Materialy Vserossiyskoy nauchno-prakticheskoy konferentsii, posvyashchennoy 100-letiyu so dnya rozhdeniya zaslužennogo rabotnika vysshey shkoly Rossiyskoy Federatsii, pochetnogo chlena Russkogo geograficheskogo obshchestva, professora, doktora geograficheskikh nauk Zemtsova Alekseya Anisimovicha* [Geomorphology and physical geography of Siberia in the XXI century. Proceedings of the All-Russian scientific and practical conference dedicated to the 100th anniversary of the birth of the honored worker of the higher school of the Russian Federation, honorary member of the Russian Geographical Society, professor, doctor of geographical sciences Alexei Anisimovich Zemtsov]. Tomsk, Tomsk State University Publ. house, 2020, pp. 209–213.
23. Chebotarev A.I. *Gidrologicheskiy slovar* [Hydrological dictionary]. Leningrad, Gidrometeoizdat Publ., 1978. 308 p.
24. Bubin M.N. Forecasting floods of the summer-autumn period. *Successes of modern natural science*, 2014, no. 12-5, pp. 550–553. In Rus.
25. Gorban A.N., Rossiev D.A. *Neyronnye seti na personalnom kompyutere* [Neural networks on a personal computer]. Novosibirsk, Nauka Publ., 1996. 276 p.
26. Tsaregorodtsev V.G. Neyroimitator NEUROPRO [NEUROPRO neurosimulator]. *Neyroinformatika i ee prilozheniya. Tezisy dokladov VI Vserossiyskogo seminarina* [Neuroinformatics and its applications. Proc. reports of VI All-Russian Seminar]. Ed. by A.N. Hunchback. Krasnoyarsk, October 2–5, 1998. pp. 207–208.
27. Bertsun A.N., Ivanenko B.P., Klestov S.A., Sryamkin V.I. Upravlenie riskami navodneniy kak sostavlyayushchaya chast intellektualnoy mnogomernoy sistemy monitoringa territoriy [Flood risk management as a component of an intelligent multidimensional monitoring system for territories]. *Innovatika-2021. Sbornik materialov XVII Mezhdunarodnoy shkoly-konferentsii studentov, aspirantov i molodykh uchennykh* [Innovatika-2021. Collection of materials of the XVII International School-Conference of students, graduate students and young scientists]. Tomsk, April 22–23, 2021. Tomsk, STT Limited Liability Company Publ., 2021. pp. 93–95.
28. Topolsky N.G., Vilisov V.Ya. *Metody, modeli i algoritmy v sistemakh bezopasnosti: mashinnoe obuchenie, robototekhnika, strakhovanie, riski, kontrol* [Methods, models and algorithms in security systems: machine learning, robotics, insurance, risks, control]. Moscow, OOO IC «RIOR» Publ., 2021. 475 p. DOI: 10.29039/02072-2.
29. Vinogradov O.V., Morozova O.A. Aspects of the use of neural networks for forecasting emergency situations. *Tekhnologii grazhdanskogo bezopasnosti*, 2021, vol. 18, no. 1 (67), pp. 23–26. In Rus. DOI: 10.54234/CST.19968493.2021.18.1.67.4.23.
30. Kolmogorov A.N. On the representation of continuous functions of several variables by superpositions of continuous functions of a smaller number of variables. *Dokl. Academy of Sciences of the USSR*, 1956, vol. 108, no. 2, pp. 179–182. In Rus.
31. Kolmogorov A.N. On the representation of continuous functions of several variables as a superposition of continuous functions of one variable. *Dokl. AN USSR*, 1957, vol. 114, no. 5, pp. 953–956. In Rus.
32. Hecht-Nielsen R. Neurocomputing: picking the human brain. *IEEE Spectrum*, 1988, March, pp. 36–41.
33. Hecht-Nielsen R. Theory of the backpropagation neural network. *Neural Networks for Human and Machine Perception*. Ed. by H. Wechsler. Vol. 2. Boston, MA, Academic Press, 1992. pp. 65–93.
34. Ivanenko B.P. *Neyrosetevoe imitatsionnoe modelirovanie neftyanykh mestorozhdeniy i gidrogeologicheskikh obyektov* [Neural network simulation modeling of oil fields and hydrogeological objects]. Tomsk, Tomsk State University Publ. House, 2014. 186 p.
35. Ivanenko B.P., Klestov S.A., Sryamkin V.I. *Neyrosetevoy prognoz prirodnykh resursov. Na primere realnykh neftyanykh mestorozhdeniy, poligonov zakhroneniya ZhRO, prognoze pavadkovykh vod* [Neural network forecast of natural resources. On the example of real oil fields, LRW disposal sites, flood water forecast]. London, LAP LAMBERT Publ. house, 2019. 190 p.
36. Sryamkin V.I., Shumilov V.N. *Sintez iskustvennogo nositelya intellekta: informatsionno-biologicheskii podkhod* [Synthesis of artificial carrier of intelligence: information-biological approach]. 4th ed., revised. Moscow, Berlin, Direct-Media LLC, 2021. 228 p.
37. Sryamkin V.I., Gorbachev S.V., Shikhman M.V. Adaptive fuzzy neural production network with MIMO-structure for the evaluation of technology efficiency. *IOP Conference Series: Materials Science and Engineering*. Tomsk, 22–24 November 2018. Tomsk, Institute of Physics Publ., 2019. pp. 012010. DOI: 10.1088/1757-899X/516/1/012010.
38. Sryamkin V.I., Gorbachev S.V., Shikhman M.V. Adaptive neuro-fuzzy classifier for evaluating the technology effectiveness based on the modified Wang and Mendel fuzzy neural production MIMO-network. *IOP Conference Series: Materials Science and Engineering*. Tomsk, 22–24 November 2018. Tomsk, Institute of Physics Publ., 2019. pp. 012037. DOI: 10.1088/1757-899X/516/1/012037.
39. Gorbachev S.V., Sryamkin V.I., Abramova T.V. Synthesis method for a neuro-fuzzy classifier based on a decision tree. *Telecommunications*, 2018, no. 9, pp. 2–7. In Rus.
40. Sryamkin V.I., Suntsov S.B., Titov V.S. Intellektualnye raspredelennye sistemy raspoznavaniya obrazov v kompleksakh monitoringa, prognoza, diagnostiki, upravleniya i obespecheniya bezopasnosti [Intelligent distributed systems of pattern recognition in complexes of monitoring, forecasting, diagnostics, control and security]. *Optiko-elektronnye pribory i ustroystva v sistemakh raspoznavaniya obrazov, obrabotki izobrazheniy i simvolnoy informatsii. Raspoznavanie-2017. Sbornik materialov XIII Mezhdunarodnoy nauchno-tekhnicheskoy konferentsii* [Optoelectronic devices and devices in systems for pattern recognition, image processing and symbolic information. Recognition-2017. Collection of materials of the XIII International Scientific and Technical Conference]. Kursk, May 16–19, 2017. Kursk, Southwestern State University, 2017. pp. 336–341.
41. Rogerson D. *Osnovy SOM* [Fundamentals of COM]. Translated from English. 2nd ed. Moscow, Russian edition Publ. and trading house, 2000. 400 p.
42. Troelsen E. *Model SOM i primenenie ATL 3.0* [Model COM and application of ATL 3.0]. Translated from English. St. Petersburg, BHV–St. Petersburg, 2000. 928 p.
43. Gorban A.N. Bystroe differentsirovanie, dvoystvennost i obratnoe rasprostranenie oshibki [Fast differentiation, duality, and error backpropagation]. *Neyroinformatika* [Neuroinformatics]. Novosibirsk, Nauka, Siberian Publishing Company of the Russian Academy of Sciences, 1998. 337 p.

Received: 24 September 2022.

Reviewed: 8 January 2023.

Information about the authors

Vladimir I. Syryamkin, Dr. Sc., professor, Honored Inventor of the Russian Federation, Honored Worker of the Higher School of the Russian Federation, Laureate of the Government of the Russian Federation in the field of education, head of the Department of Quality Management, National Research Tomsk State University.

Boris P. Ivanenko, Cand. Sc., senior researcher, National Research Tomsk State University.

Semen A. Klestov, assistant, National Research Tomsk State University.

Maria D. Khilchuk, engineer, National Research Tomsk State University.