

Дистанционное зондирование сред

УДК 621.396.67

НЕЙРОННАЯ СЕТЬ В СВЧ РАДИОМЕТРИЧЕСКОЙ СИСТЕМЕ МОНИТОРИНГА АТМОСФЕРЫ

Каряев Вадим Валентинович

преподаватель кафедры «Программная инженерия» Муромского института (филиала) ФГБОУ ВО «Владимирский Государственный университет имени А.Г. и Н.Г. Столетовых».
E-mail: 10xgg@mail.ru

Ростокин Илья Николаевич

доктор технических наук, доцент, профессор кафедры «Управление и контроль в технических системах» Муромского института (филиала) ФГБОУ ВО «Владимирский Государственный университет имени А.Г. и Н.Г. Столетовых».
E-mail: rostockin.ilya@yandex.ru

Федосеева Елена Валерьевна

доктор технических наук, доцент, профессор кафедры радиотехники Муромского института (филиала) ФГБОУ ВО «Владимирский Государственный университет имени А.Г. и Н.Г. Столетовых».
E-mail: elenafedoseeva@yandex.ru

Ростокина Елена Анатольевна

кандидат технических наук, доцент кафедры «Управление и контроль в технических системах» Муромского института (филиала) ФГБОУ ВО «Владимирский государственный университет имени А.Г. и Н.Г. Столетовых».
E-mail: arostokina@yandex.ru

Адрес: 602264, Российская Федерация, Владимирская обл., г. Муром, ул. Орловская, д. 23.

Аннотация: Проанализированы основные требования к нейронным сетям в системах мониторинга и прогнозирования состояния атмосферы. Исходя из задачи краткосрочного прогнозирования метеопараметров по данным СВЧ радиометрических измерений мощности собственного радиотеплового излучения атмосферы, определены входные и выходные характеристики системы, тип и структура нейронной сети. Предложена обобщённая схема системы СВЧ радиометрического мониторинга атмосферы, включающая информационную систему, систему аппаратного обеспечения, нейронную сеть и базу данных. Определены основные функциональные требования ко всем частям обобщённой системы и основные принципы их совместного функционирования. Особо выделена информационная система, как центральная часть обобщённой системы, обеспечивающей взаимодействие остальных частей системы мониторинга атмосферы. Рассмотрены и реализованы принципы формирования базы исходных данных при поступлении на вход АЦП сигналов с многоканального квадратичного детектора. Определена процедура обучения нейронной сети по данным суточных многочастотных СВЧ радиометрических измерений радиотеплового излучения атмосферы с предварительной оценкой наличия корреляции между величиной выходных сигналов радиометра и медианными численными данными значений метеопараметров, получаемых с мобильной метеостанции. Получены результаты численного эксперимента с нейронной сетью, выполнено прогнозирование выходных параметров системы для текущего момента и с упреждением на два часа.

Ключевые слова: нейронная сеть, мониторинг атмосферы, многочастотная СВЧ радиометрическая система, прогнозирование метеопараметров, радиотепловое излучение.

Введение

Для решения задач метеорологии, связанных с прогнозированием погодных условий с целью

принятия оперативно-хозяйственных решений, а также составления сверхкраткосрочных прогнозов опасных явлений, целесообразным

является повсеместное внедрение систем мониторинга атмосферы. Это позволит осуществлять постоянный непрерывный контроль за её состоянием и оперативно принимать решения с учётом наиболее вероятного развития событий.

Разработка программного обеспечения для подобных систем представляет собой сложную задачу, обусловленную как большими объёмами постоянно получаемых экспериментальных данных от систем мониторинга, так и необходимостью быстро реагировать на постоянно меняющуюся обстановку. При этом необходимо учитывать, что обработке будут подвергаться экспериментальные данные, получаемые с помощью микроволновых радиометрических систем, следовательно, потребуется разработать способы выявления закономерностей различных процессов, происходящих в атмосфере, и их визуализации. Ранее решение подобных задач базировалось на основе постоянного мониторинга алгоритмов работы системы за длительный период времени и требовало больших временных затрат на проверку правильности принятых решений. Зачастую приходилось задействовать несколько специалистов узкой направленности с большим опытом работы.

При решении задач по прогнозированию, обработке и моделированию различного рода явлений и ситуаций все большее распространение получают нейросетевые технологии, являющиеся современным средством анализа различных данных. Основной причиной их широкого распространения является способность нейронных сетей автоматически выделять из массива данных ключевые признаки, необходимые для решения поставленной задачи [1].

Определение основных закономерностей микроволновых радиометрических сигналов в атмосфере при воздействии различных дестабилизирующих факторов зависит от большого числа неодинаковых по значимости факторов, поэтому для их выявления как нельзя лучше подходят нейросетевые технологии.

Применение нейронных сетей позволит значительно сократить время на поиск зависимостей результирующих данных от входных параметров за счёт переобучения сети и подбора входных весовых коэффициентов каждого из нейронов на каждом слое сети на всем этапе обучения. Несомненным достоинством нейронных сетей также является возможность их дообучения, на основе вновь полученных фактических данных.

В настоящее время ведётся активная работа в данном направлении, так в Google Research применяется нейронная сеть MetNet для прогнозирования осадков с интервалом от 2 мин до 8 часов [2], а NOAA использует физическую модель для прогнозирования осадков с упреждением 7–8 часов.

Авторами предлагается использовать системы мониторинга атмосферы для составления сверхкраткосрочных прогнозов опасных явлений, установив зависимости уровня микроволновых радиометрических сигналов системы мониторинга атмосферы от самого состояния атмосферы, что позволит осуществлять прогнозирование с учётом «местных особенностей», характерных только для конкретного географического района размещения системы.

Использование нейросетевых технологий в системах мониторинга атмосферы

Рассмотрим систему мониторинга атмосферы как систему с определёнными входными и выходными данными. Передаточная функция такой системы зависит от наборов входных данных и может носить как линейный, так и нелинейный характер

$$y = f(x) + \varepsilon, \quad (1)$$

где $f(x)$ — неизвестная передаточная функция; x — вектор входных переменных; ε — вектор ошибок модели.

В качестве входных данных предлагается использовать массив данных многочастотных микроволновых каналов, а в качестве выходных — список вероятностей наступления по-

тенциально опасных метеоявлений.

Определение передаточной функции, связывающей входные и выходные параметры системы на основании имеющихся эмпирических связей, является основной задачей, для решения которой используется нейронная сеть.

Для решения задач классификации, аппроксимации и прогнозирования используются сети прямого распространения, такие как хорошо изученный многослойный персептрон, структура которого приведена на рис. 1 [3]. Каждый нейрон последующего слоя связан со всеми нейронами предыдущего, а «важность» этих связей определяется синаптическими весами W_{ij} и W_{jk} .

Зависимость выходных данных системы от вектора входных данных определяется на основании обрабатывающих узлов — нейронов, расположенных в скрытом слое. Процесс обработки начинается с входного слоя, на котором, как правило, данные не обрабатываются, а передаются на первый скрытый уровень нейронов с учётом синаптических весов W_{ij} . Пройдя систему скрытых слоев, преобразованная информация поступает на выходной слой, который представляет собой предполагаемый вектор искомым величин.

В ходе построения архитектуры нейросети необходимо определить количество скрытых слоёв и количество нейронов в них. Количество нейронов во входном и выходном слоях определяется количеством входов и выходов сети. Задача определения оптимального количества нейронов в скрытых слоях является основополагающей при создании архитектуры нейросети. При недостаточном количестве нейронов обучение нейросети невозможно, избыточное их количество ведёт к увеличению времени обучения. Также возможен эффект излишнего обучения, выражаемый в получении идеальных результатов на обучаемой выборке тестового набора данных и некорректное прогнозирование результатов при подаче на её вход реальных данных.

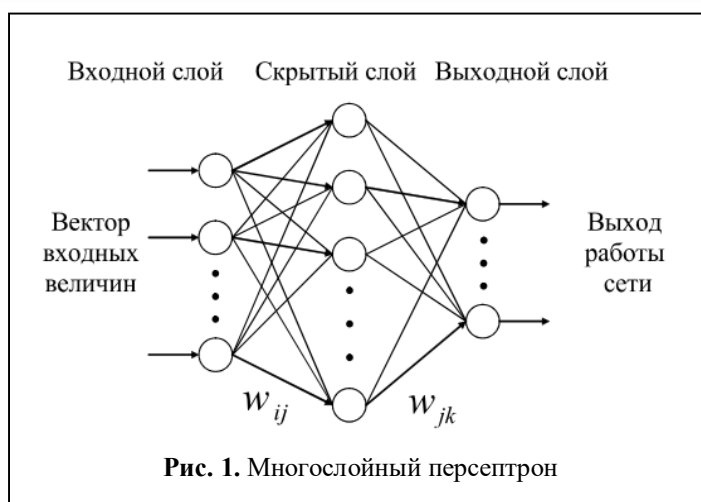


Рис. 1. Многослойный персептрон

Для определения количества скрытых слоёв и оптимального числа нейронов в скрытых слоях в настоящее время не существует четко выработанной методики. Например, в [4] рекомендуется число скрытых слоёв и количество нейронов на них определять эмпирическим путём.

В [5] в соответствии с теорией Колмогорова — Арнольда — Хехт — Нильсена указано, что для аппроксимации непрерывной функции достаточно одного скрытого слоя с числом нейронов в скрытом слое

$$k = 2N + 1, \quad (2)$$

где k — число нейронов в скрытом слое; N — размерность входного вектора.

На практике чаще всего используются сети, имеющие один или два скрытых слоя и число нейронов в каждом слое от N до $3N$.

Для определения количества нейронов скрытых слоёв сети используется правило геометрической пирамиды [6]. Оно утверждает, что для многих практических сетей количество нейронов имеет форму пирамиды, при этом число нейронов уменьшается от входа к выходу в геометрической прогрессии.

В качестве активационной функции для нейронов наиболее перспективным видится применение следующих функций:

- а) сигмоидальная логистическая функция

$$F(x) = \frac{1}{1 + e^{-x}}; \quad (3)$$

- б) гиперболический тангенс

$$F(x) = \tanh(x) = \frac{2}{1 + e^{-2x}} - 1; \quad (4)$$

в) экспоненциальный линейный блок (ELU)

$$F(x) = \begin{cases} e^x - 1, & \text{при } x < 0, \\ x, & \text{при } x \geq 0; \end{cases} \quad (5)$$

г) SoftPlus

$$F(x) = \ln(1 + e^x). \quad (6)$$

Приведённые функции дифференцируемы на всей оси абсцисс, что является весьма важным для процесса обучения нейронной сети, а также имеют особенность усиливать слабый сигнал нейронов и сглаживать сильный.

Задачей обучения нейронной сети является определение весовых коэффициентов и смещений, на основании которых значение прогнозируемых параметров, полученных с использованием передаточной функции $f(x)$ приближается к реальному.

В настоящее время создано большое количество программных систем для обучения нейронных сетей. Среди них наиболее популярны Caffe, Theano, TensorFlow, Torch и CNTK [1]. Перечисленные системы обучения могут использовать для обучения как многоядерные процессоры, так и графические видеоадаптеры (GPU) (включая оптимизированную библиотеку cuDNN).

Для обучения нейросети наиболее целесообразным видится использование алгоритма обратного распространения ошибки, минимизирующей суммарную квадратичную ошибку [7–9]. Он предполагает вычисление ошибки выходного слоя, а также коррекцию синоптических весов нейронов в соответствии с их текущими значениями. При этом в качестве критерия оценки точности прогнозирования возможно применение среднеквадратической ошибки (MSE)

$$MSE = \frac{1}{N} \sum_{n=1}^N (y_n^{\text{э}} - y_n^{\text{п}})^2, \quad (7)$$

где N — количество экспериментальных данных; $y_n^{\text{э}}$ — экспериментальные данные; $y_n^{\text{п}}$ — прогнозируемые данные.

Предлагаемая модель системы мониторинга атмосферы

Обобщённую систему мониторинга атмосферы можно представить, как взаимодействие следующих систем: информационной системы, отвечающей за обработку, накопление и хранение полученных статистических данных; системы аппаратного обеспечения, отвечающей за сбор данных; нейронной сети, проводящей анализ массива данных и выделяющей ключевые признаки, необходимые для последующего выведения математической зависимости результирующих данных от входных. Структурная схема такой модели представлена на рис. 2.

Необходимость использования базы данных (БД) в предлагаемой модели обусловлена следующим:

- наличие большого объёма данных. Некоторые файловые системы, использование которых предполагается в данной системе, имеют ограничение на максимальный размер файла, а хранение большого количества более мелких файлов усложнит поиск и получение необходимых данных;
- возможность введения различных ограни-

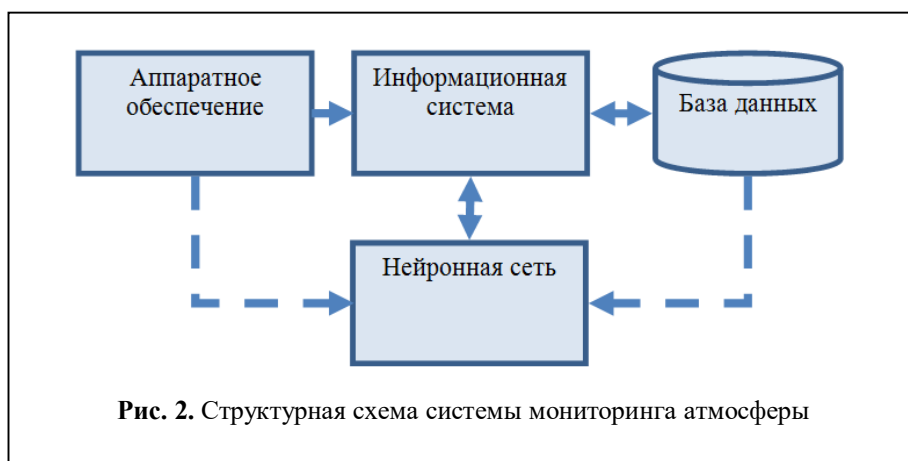


Рис. 2. Структурная схема системы мониторинга атмосферы

чений для обеспечения безопасности (ограничение права доступа на чтение, запись и внесение изменений);

- возможность использования дифференциальных резервных копий;

- возможность использования транзакций, что исключает возможность повреждения хранящихся данных при сбоях или отключении электроэнергии в момент записи изменений в БД;

- возможность многопользовательского обращения к данным;

- возможность применения (создания) дополнительных программных продуктов, используемых вне описываемой системы.

В соответствии с представленной на рис. 2 схемой, информационная система является центром построения всей модели и выступает в роли своеобразной «прослойки» между базой данных и остальными частями модели. Такое построение позволит исключить занесение в БД ошибочных или некорректных данных, поступающих с аппаратной части и в тоже время дает возможность отображать данные в удобочитаемом формате (например, в виде таблиц или диаграмм), делать выборки данных по определенным, заданным пользователем условиям, а также при необходимости вносить коррекции.

В качестве аппаратного обеспечения может выступать совокупность следующих систем: трёхдиапазонная СВЧ радиометрическая система с реализацией компенсации фоновых шумов при приёме на дополнительный антенный канал [10–12], аналого-цифровой преобразователь (АЦП) и метеостанция. Необходимо отметить, что метеостанция может быть исключена из описываемого набора, а вместо неё могут использоваться данные получаемые от метеорологических наземных станций.

Практическая реализация аппаратной и информационной систем, а также создание базы данных как составных частей системы мониторинга атмосферы, представляет собой весьма сложную, но вполне решаемую задачу.

Наибольшие трудности вызывает построение и дальнейшее обучение нейросети с целью выведения математической зависимости результирующих данных от входных.

Функционирование предлагаемой системы мониторинга атмосферы

Функционирование системы мониторинга атмосферы начинается с подачи на входы АЦП сигналов от многоканального квадратичного детектора и подключения АЦП к персональному компьютеру через USB-порт или по шине данных SPI (I2C).

Занесение данных, получаемых от аппаратного обеспечения, в БД осуществляется через информационную систему. На вход информационной системы поступают оцифрованные СВЧ — радиометрические данные, получаемые от АЦП, которые проверяются на корректность, при необходимости обрабатываются, и записываются в виде числового массива с указанием времени их получения в таблицу БД.

Обучение нейронной сети производится под непрерывным «надзором» информационной системы при снабжении её необходимыми данными на всём этапе обучения. Процесс обучения останавливается при достижении нейронной сети заданного порога достоверности. Исключение информационной системы из процесса обучения возможно при условии использования сторонних программных библиотек, которые могут контролировать процесс обучения и получать данные из БД.

После успешного обучения нейронная сеть может быть испытана в «полевых» условиях, т.е. путём исследования прогнозов, построенных нейронной сетью на основе данных, полученных напрямую от аппаратного обеспечения.

После завершения «полевых» испытаний обученной нейронной сети теоретически возможно выведение математической зависимости результирующих данных от входных, при условии, что известны весовые коэффициенты

нейронов на каждом слое и известны функции активации нейронов. Следовательно, задача выведения математической формулы сводится к последовательному составлению математических выражений для каждого слоя нейронной сети, начиная со второго (первый слой является входным) и их дальнейшей оптимизации.

Вычислительный эксперимент

На данный момент создан прототип информационной базы данных, на основе PostgreSQL, в которую загружено приблизительно 99 миллионов записей данных, полученных от аналого-цифрового преобразователя и представляющих из себя данные по 8 радиометрическим каналам, а также приблизительно 21 тысяча измерений погодных условий (температура, влажность, скорость ветра, осадки и т.д.).

Следуя из того, что погодные данные обновляются через 5 минут, а радиометрические данные — через 0,1 секунды, для сопоставления погодных данных с радиометрическими последние выбирались в диапазоне $\pm 2,5$ минуты от времени измерения погодных условий и вычислялось медианное значение. Полученные значения лучше отображают реальную картину радиотеплового излучения атмосферы, так как медиана менее подвержена искажениям в виде «выбросов» или «провалов» микроволнового сигнала, нежели среднее арифметическое значение. Сопоставленные значения погодных явлений и радиометрических измерений представлены в базе данных в виде материализованного представления.

На рис. 3, рис. 4 приведены результаты применения медианы к радиометрическим данным (данные отображены за одни сутки). Также данные графики наглядно отображают взаимосвязь радиометрических и погодных измерений.

Используя небольшой скрипт, написанный на языке программирования Python, были вычислены корреляционные зависимости каждо-

го из каналов радиометрических измерений по отношению к температуре и влажности (рис. 4) для подтверждения существования зависимости между графиками, приведенными на рис. 3.

Для определения возможности применения нейронной сети в системе мониторинга атмосферы проводился вычислительный эксперимент, в ходе которого была спроектирована нейронная сеть прямого распространения, имеющая два скрытых слоя с функцией активации нейронов SoftMax. В качестве входных данных были использованы ранее собранные радиометрические данные при мониторинге атмосферы за один год, а в качестве выходных — текущая температура и температура с упреждением в два часа, как наиболее показательные и изменчивые данные.


На рис. 5 представлены результаты обучения нейронной сети: по оси абсцисс — порядковый номер измерения в интересующей выборке данных из базы данных, по оси ординат — нормированные значения экспериментальных и прогнозируемых измерений температуры в интервале от 0 до 1. Для наглядности данные приводятся на одном рисунке.

Нормированные значения определяются по формуле

$$n_{\text{норм}} = \frac{n_i - \min(n)}{\max(n) - \min(n)}, \quad (8)$$

где n_i — текущее значение экспериментальных измерений; $\min(n)$ — минимальное значение экспериментальных измерений; $\max(n)$ — максимальное значение экспериментальных измерений.

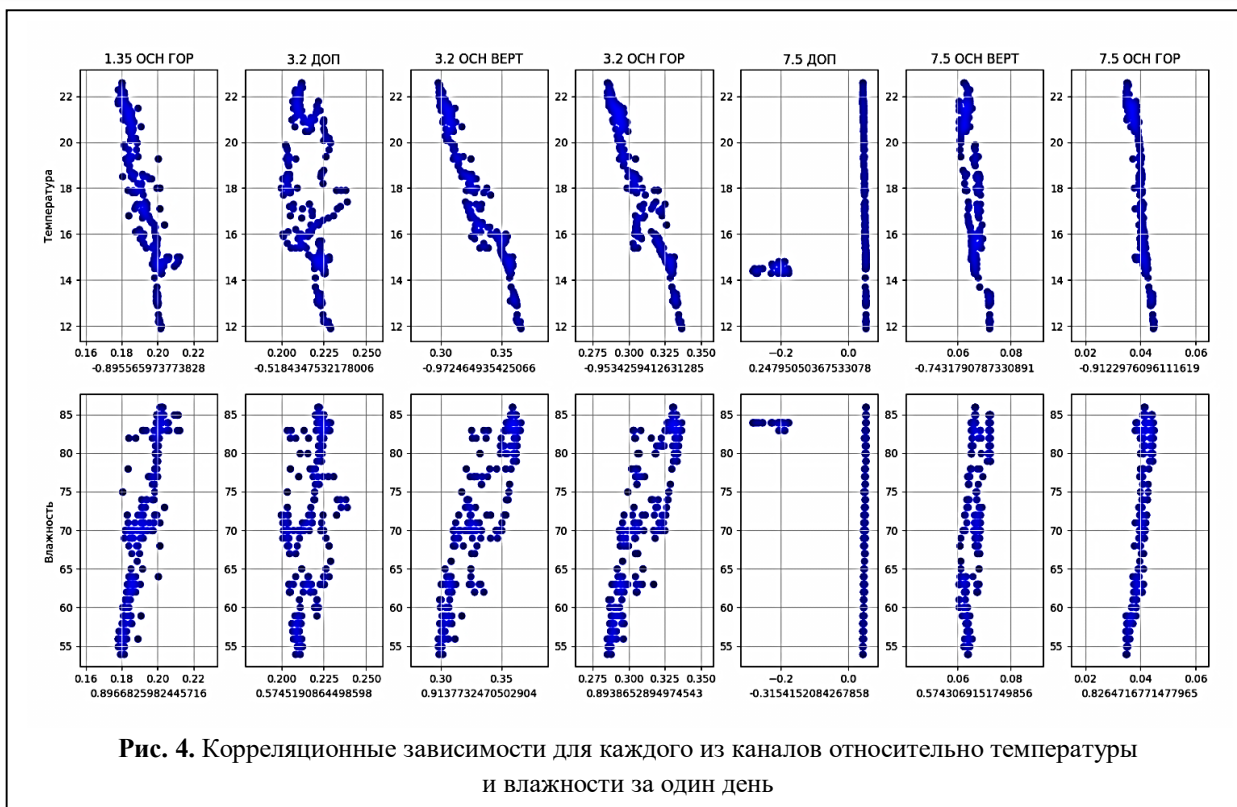
Обучение нейронной сети проводилось в течение 100 тысяч эпох, что вполне достаточно для проверки возможности обучения нейронной сети и для наглядности эксперимента. По результатам эксперимента среднеквадратичная ошибка составила 0,0026 для температуры, зафиксированной в то же время, что и СВЧ-радиометрические сигналы (рис. 5, а) и 0,0038 для температуры с упре-



ждением на два часа (рис. 5, б).

Проведённый эксперимент показал принципиальную возможность применения нейронных сетей для прогнозирования погодных явлений с использованием многочастотных

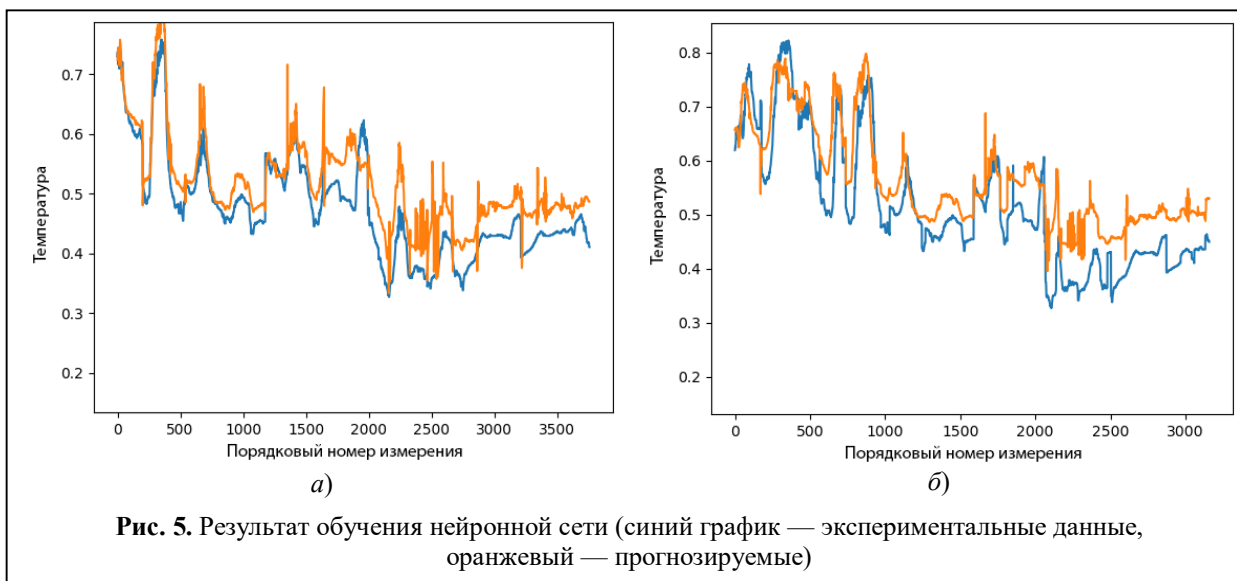
СВЧ-радиометрических сигналов в качестве входных данных. Увеличение числа эпох предположительно приведёт к улучшению показателей.



Заключение

Возможность применения нейронных сетей для установления зависимости мощности микроволновых радиометрических сигналов системы мониторинга атмосферы от самого состояния атмосферы, а также для прогнозирования состояния атмосферы на основе статистических данных, собранных за прошедшие периоды, выводит мониторинг атмосферы на

качественно новый уровень. Получение математической модели выше описанных зависимостей из весовых коэффициентов обученной нейронной сети позволит сократить процессорное время для прогнозирования опасных метеоявлений и решить задачу достоверного краткосрочного прогнозирования развития опасных атмосферных явлений.



Литература

1. Созыкин А.В. Обзор методов обучения глубоких нейронных сетей // Вестник ЮУрГУ. Серия: Вычислительная математика и информатика. 2017. Т. 6, № 3. С. 28–59. DOI: 10.14529/cmse170303.
2. Kalchebremer N., Sonderby C. A Neural Weather Model for Eight-Hour Precipitation Forecasting [Электронный ресурс]. URL: <https://ai.googleblog.com/2020/03/a-neural-weather-model-for-eight-hour.html> (дата обращения 14.09.2020).
3. Евдокимов И.А., Солодовников В.И. Автоматизация построения нейронной сети в рамках объектно-ориентированного подхода // Новые информационные технологии в автоматизированных системах. 2015. С. 89–97.
4. Назаров А.В., Лоскутов А.И. Нейросетевые алгоритмы прогнозирования и оптимизации систем. СПб: Наука и техника, 2003. 380 с.
5. Осовский С. Нейронные сети для обработки информации. М.: Финансы и статистика, 2002. 344 с.
6. Masters T. Practical Neural Network Recipes in C++. San-Diego, USA: Academic Press Professional, Inc., 1993. 493 p.
7. Галушкин А.И. Теория нейронных сетей. М.: ИПРЖР, 2000. 348 с.
8. Минский М., Пейснерт С. Перцептроны. М.: Мир. 1971. 261 с.
9. Круглов В.В., Борисов В.В. Искусственные нейронные сети. М.: Горячая линия — Телеком, 2002. 382 с.
10. Ростокин И.Н., Федосеева Е.В., Шукин Г.Г., Ростокина Е.А. Задачи и принципы организации сбора и обработки данных многочастотной СВЧ радиометрической системы контроля метеорообразований с компенсацией фоновых шумов // Радиотехнические и телекоммуникационные системы. 2017. № 1 (25). С. 3–16.
11. Федосеева Е.В. Системы радиотеплолокационного контроля метеопараметров с компенсацией помехового влияния внешней среды // Приборы и системы. Управление, контроль, диагностика. 2015. № 9. С. 44–48.
12. Ростокин И.Н., Федосеева Е.В. Вопросы построения многочастотной СВЧ радиометрической системы дистанционного зондирования облачной атмосферы с компенсацией фонового излучения // Радиотехнические и телекоммуникационные системы. 2015. № 1 (17). С. 5–12.

Поступила 15 сентября 2020 г.

English

NEURAL NETWORK IN MICROWAVE RADIOMETRIC MONITORING SYSTEM OF ATMOSPHERE

Vadim Valentinovich Karyaev — Lecturer of “Software Engineering” Department, Murom Institute (Branch) Federal State Budgetary Educational Institution of Higher Professional Education “Vladimir State University named after A.G. and N.G. Stoletovs”.
E-mail: 10xgg@mail.ru

Ilya Nikolaevich Rostokin — Doctor of Engineering Sciences, Associate Professor, Professor of Department of Monitoring and Control in Engineering Systems, Murom Institute (Branch) Federal State Budgetary Educational Institution of Higher Professional Education “Vladimir State University named after A.G. and N.G. Stoletovs”.
E-mail: rostockin.ilya@yandex.ru

Elena Valeryevna Fedoseeva — Doctor of Engineering Sciences, Associate Professor, Professor of Radio Engineering Department, Murom Institute (Branch) Federal State Budgetary Educational Institution of Higher Professional Education “Vladimir State University named after A.G. and N.G. Stoletovs”.
E-mail: elenafedoseeva@yandex.ru

Elena Anatoljevna Rostokina — Candidate of Engineering Sciences, Associate Professor, Department of Monitoring and Control in Engineering Systems, Murom Institute (Branch) Federal State Budgetary Educational Institution of Higher Professional Education “Vladimir State University named after A.G. and N.G. Stoletovs”.
E-mail: arostokina@yandex.ru

Address: 602264, Russian Federation, Vladimir region, Murom, Orlovskaya st., 23.

Abstract: Basic requirements for neural networks in atmosphere’s monitoring and forecasting systems are analyzed. Input and output system performance data as well as neural network type and its structure are defined in view of target task of short-term forecasting of weather parameters using microwave radiometric

measurements of atmosphere's intrinsic radiothermal emission power. Options for solving the problem of constructing and training neural network are considered. Input performance data is set: an array of measurement data for multi-frequency microwave radiometric system. Neural network construction as feed-forward network with the necessary number of hidden layers is defined. Choice selection of error back propagation algorithm is justified to train neural network in microwave radiometric monitoring system of atmosphere. Generalized chart of microwave radiometric monitoring system of atmosphere is proposed comprising an information system, a hardware system, a neural network, and a database. Basic functional requirements for all parts of generalized system and key principles of their joint functioning are defined. Information system is highlighted as generalized system core ensuring interaction between other parts of atmospheric monitoring system. There are examined and implemented principles of forming initial database when signals come into ADC input from multi-channel quadratic detector of three-band microwave radiometric system taking into account a large number of measurement results, security requirements, backup capability, availability to solve extra analysis tasks. The principles of database formation are described in reviewed computational experiment. The procedure is defined for training neural network controlled by information system according to 24-hour multi-frequency microwave radiometric measurements of atmospheric radiothermal radiation with a prior assessment of correlation between the value of radiometer output signals and median numerical datum values of weather parameters for atmospheric ground layer obtained from mobile weather station. Results are presented of neural network numerical experiment with estimation of predicting procedure for system output parameters for the current moment and with two-hour lead.

Keywords: neural network, atmospheric monitoring, multi-frequency microwave radiometric system, weather parameter forecasting, radiothermal emission.

References

1. *Sozykin A.V.* Review of training methods for deep neural networks. Bulletin of SUSU. Series: Computational mathematics and computer science. 2017. Vol. 6, No. 3. Pp. 28–59. DOI: 10.14529/cmse170303
2. *Kalchebremer N., Sonderby C.* A Neural Weather Model for Eight-Hour Precipitation Forecasting [Electronic source]. URL: <https://ai.googleblog.com/2020/03/a-neural-weather-model-for-eight-hour.html> (access date 14.09.2020).
3. *Evdokimov I.A., Solodovnikov V.I.* Automation of neural network construction in the framework of object-oriented approach. New information technologies in automated systems. 2015. Pp. 89–97.
4. *Nazarov A.V., Loskutov A.I.* Neural network algorithms for forecasting and optimizing systems. Saint Petersburg: Nauka i Tekhnika, 2003. 380 p.
5. *Osovsky S.* Neural networks for information processing. Moscow: Finance and statistics, 2002. 344 p.
6. *Masters T.* Practical Neural Network Recipes in C++. San-Diego, USA: Academic Press Professional, Inc., 1993. 493 p.
7. *Galushkin A.I.* Theory of neural networks. Moscow: IPRZhR, 2000. 348 p.
8. *Minsky M., Peispart S.* Perceptrons. Moscow: Mir. 1971. 261 p.
9. *Kruglov V.V., Borisov V.V.* Artificial neural networks. Moscow: Hotline-Telecom, 2002. 382 p.
10. *Rostokin I.N., Fedoseeva E.V., Shchukin G.G., Rostokina E.A.* Tasks and principles of data collection and processing of a multi-frequency microwave radiometric system for monitoring weather formations with background noise compensation. Radio engineering and telecommunication systems. 2017. No. 1 (25). Pp. 3–16.
11. *Fedoseeva E.V.* Systems of radioteplolocation control of meteorological parameters with compensation of the external environment's influence. Devices and systems. Management, monitoring, diagnostics. 2015. Iss. 9. Pp. 44–48.
12. *Rostokin I.N., Fedoseeva E.V.* Questions of constructing a multi-frequency microwave radiometric system for remote sensing of the cloud atmosphere with background radiation compensation. Radio engineering and telecommunication systems. 2015. No. 1 (17). Pp. 5–12.