

УДК 520.16-17

## АНАЛИЗ РЕЗУЛЬТАТОВ ИЗМЕРЕНИЙ АСТРОКЛИМАТА В МИЛЛИМЕТРОВОМ ДИАПАЗОНЕ ДЛИН ВОЛН С ИСПОЛЬЗОВАНИЕМ МЕТОДОВ МАШИННОГО ОБУЧЕНИЯ

© 2024 Т. А. Хабарова<sup>1,2\*</sup>, П. М. Землянуха<sup>1</sup>,  
Е. М. Домбек<sup>2,1</sup>, А. С. Марухно<sup>3</sup>, В. Ф. Вдовин<sup>1,3,2</sup>

<sup>1</sup>Институт прикладной физики РАН, Нижний Новгород, 603950 Россия

<sup>2</sup>Нижегородский государственный университет им. Н. И. Лобачевского,  
Нижний Новгород, 603950 Россия

<sup>3</sup>Специальная астрофизическая обсерватория РАН, Нижний Архыз, 369167 Россия

Поступила в редакцию 1 сентября 2023 года; после доработки 28 ноября 2023 года; принята к публикации 18 декабря 2023 года

В настоящей работе представлен метод оценки осаждаемого водяного пара по радиометрическим данным при помощи методов машинного обучения. Приведены результаты исследования осаждаемого водяного пара для территорий селения Чираг (Дагестан), пика Терскол (Приэльбрусье), обсерватории «Бадары» (Бурятия) и архипелага Шпицберген. Проведен сравнительный анализ оценки осаждаемого водяного пара для территории «Бадар» по данным GNSS, MERRA-2, радиометра водяного пара и прогнозирования значений с помощью методов машинного обучения на основе данных микроволнового радиометра МИАП-2.

Ключевые слова: миллиметровая астрономия — методы: анализ данных

### 1. ВВЕДЕНИЕ

Одними из наиболее важных характеристик атмосферы в приложении к миллиметровой астрономии являются оптическая толщина атмосферы и количество осаждаемых паров воды (PWV). Изменение данных величин в течение длительных временных периодов определяет пригодность мест для астрономических наблюдений (Ruzhentsev and Mihailov, 2010; Bubnov et al., 2019).

Измерение оптической толщины возможно с помощью радиометра, в том числе по методу разрезов (см., например, Kislyakov and Stankevich, 1967; Bubnov et al., 2017). Оптическая толщина является частотно-зависимой оценкой. Величина PWV таковой не является, однако измерить ее напрямую можно только с помощью аэрозондов. Косвенные измерения PWV возможны с использованием радиометра водяного пара (РВП), посредством ИК-фотометрии, по тропосферным задержкам сигналов глобальных навигационных систем (GNSS), с помощью двухлучевых оптических приборов, телескопов или из расчета глобальных метеорологических моделей (Panchuk and Afanasiev, 2011).

\*E-mail: t.habarova@ipfran.ru

Panchuk and Afanasiev (2011), Zakharov et al. (2018), Bubukin et al. (2023) показали расхождение оценок величин PWV, полученных разными методами. Расхождения связаны с аппаратурными эффектами и ограниченностью привлекаемых моделей атмосферы. Однако на данный момент объем накопленных данных велик, что позволяет предложить статистический метод учета расхождений.

В последнее время методы машинного обучения получают все большее распространение в задачах астрономии. Недавно начали появляться работы, в которых применяются методы статистического анализа астроклиматических условий. Например, Milli et al. (2019) используют искусственные нейронные сети (ИНС) для прогнозирования оптической турбулентности в процессе наблюдений. Существуют работы (например, Bolbasova and Lukin, 2022), в которых предложено применение методов статистической классификации для анализа погодных условий и других факторов, влияющих на наблюдательные программы.

В настоящей работе представлен новый подход для оценки величины PWV по результатам измерений радиометра по методу разрезов. Новизна подхода заключается в переходе от физической модели поглощения излучения в атмосфере к статистической модели на основе ИНС. Для ее вычисления

**Таблица 1.** Время сессий измерений, географические координаты, высоты над уровнем моря для различных мест наблюдений

Место	Время наблюдений	Географические координаты		Высота над уровнем моря, м
Бадары	04/06/2016–10/06/2017	51° 46' 11" с. ш.	102° 14' 04" в. д.	813
Шпицберген	09/06/2018–03/06/2019	78° 06' 05" с. ш.	14° 11' 53" в. д.	27
Терскол	24/04/2020–27/07/2020	43° 16' 29" с. ш.	42° 30' 03" в. д.	3100
Чираг	18/09/2022–13/04/2023	41° 50' 01" с. ш.	47° 25' 50" в. д.	2270

используются результаты климатического моделирования. используются результаты климатического моделирования. достоверность оценки может использоваться как характеристика применимости метода для отдельных мест и сессий наблюдений.

В разделе 2 детально представлены используемые в работе данные для различных мест наблюдений. Раздел 3 содержит подробное описание статистических моделей, применяемых в нашем исследовании, в нем также приводится обоснование выбора конкретных моделей. Разделы 4 и 5 посвящены результатам оценки PWV и их обсуждению. В разделе 6 сформулированы выводы на основе наших исследований.

## 2. ИСПОЛЬЗУЕМЫЕ ДАННЫЕ

В качестве исходных данных для методов машинного обучения в работе используются временные ряды напряжений детектора радиометрической системы МИАП-2, измеренные с временным разрешением в 10 минут. Напряжение детектора пропорционально яркостной температуре неба, усредненной по полосе приема и диаграмме направленности. Измерения проводились на шести углах, от зенита до горизонта. Радиометр работает по методу разрезов в окнах прозрачности 2 мм и 3 мм независимо (Nosov et al., 2016). Необработанные временные ряды, полученные системой МИАП-2, а также оценки величин оптической толщины доступны в публичном архиве (Vubnov, 2021).

Выборка включает результаты наблюдений в обсерваториях «Бадары» и «Пик Терскол», на территории архипелага Шпицберген и в селе Чираг (Дагестан). В таблице 1 представлены координаты мест наблюдений, их высота над уровнем моря, а также время сессий измерений. Атмосферные условия в этих местах сильно отличаются, что позволило провести апробацию подхода.

В течение сессий наблюдений в селе Чираг прибор был частично неисправен: при отрицательных температурах система МИАП-2 не всегда принимала заданные программой углы поворота. Одной

из задач данной работы была проверка статистических моделей на временных периодах, для которых известно, что прибор был исправен.

В качестве целевого множества при построении статистических моделей в работе используются данные погодной модели MERRA-2 (GMAO, 2015). Они представляют усредненные по часу значения количества осаждаемого водяного пара PWV и имеют пространственное разрешение  $0.5 \times 0.625$ .

В работе также проводится сравнение данных PWV(MERRA-2) с оценками количества осаждаемого водяного пара, полученными в обсерватории «Бадары» методом тропосферных задержек (GNSS) и радиометром водяного пара (РВП или WVR — Water Vapor Radiometer) производства ИПА РАН (Ilin et al., 2013): PWV(GNSS) и PWV(РВП) соответственно.

## 3. ОПИСАНИЕ СТАТИСТИЧЕСКИХ МОДЕЛЕЙ

Поскольку различные подходы к измерениям астроклиматических параметров атмосферы имеют ограничения, связанные с аппаратными и методическими особенностями, результаты измерений должны подвергаться перекрестной проверке и валидации. Ниже представлен ряд подходов, которые использовались в данной работе для вычислений значений PWV.

### 3.1. Предварительная обработка данных

Выборки MERRA-2 и МИАП-2 имеют разное временное разрешение, поэтому были приведены к единой временной шкале с разрешением в один час. Предварительная обработка данных помогает снизить вычислительную сложность моделей машинного обучения. С целью достижения однородности данных выборки МИАП-2 и MERRA-2 были пересчитаны в диапазоны  $[-1; 1]$  и  $[0; 1]$  с помощью стандартной процедуры MinMaxScaler из библиотеки scikit-learn (Kramer and Kramer, 2016). Процедура нормализации для данных МИАП-2 в

2-мм и 3-мм диапазонах применялась отдельно для каждого места наблюдения.

Исходные данные МИАП-2 состоят из измерений в 2-мм и 3-мм диапазонах на шести углах места и содержат набор сигналов. В качестве предварительной подготовки данных использовалась процедура уменьшения размерности, что позволило сократить размерность набора данных для статистических моделей. В работе рассматриваются следующие методы снижения размерности:

- анализ основных компонент (Principal Component Analysis (PCA), Tipping and Bishop, 1999);
- анализ независимых компонент (Independent Component Analysis (ICA), Hyvärinen and Oja, 2000);
- факторный анализ (Factor Analysis (FA), Merrifield, 1969).

Методы снижения размерности были применены к нормализованному набору, состоящему из данных Шпицбергена, Чирага, обсерваторий «Бадары» и «Пик Терскол». В отличие от нормализации, коэффициенты преобразования в методах снижения размерности вычислялись для общего массива данных. Был выбран такой метод снижения размерности, при котором коэффициент детерминации  $R^2$  был наибольшим между целевой функцией и результатами, полученными после уменьшения размерности с помощью статистических моделей. В результате в работе был использован метод ICA с десятью компонентами. После применения процедуры снижения размерности выборка делилась на обучающую и тестовую и использовалась в регрессионных моделях.

### 3.2. Метод $k$ -ближайших соседей

Одним из вариантов построения регрессионной зависимости («предсказания») PWV может быть метод  $k$ -ближайших соседей ( $k$ -БС, Cover and Hart, 1967), суть которого состоит в линейной интерполяции между элементами обучающей выборки. Однако, поскольку  $k$ -БС является методом интерполяции, полученная регрессионная зависимость неизбежно включает ошибки, связанные с шумами. Они могут накапливаться и приводить к особенностям — физически не обусловленным выбросам и ступенькам.

Ранее метод  $k$ -БС был применен Vubnov et al. (2021) для измерений на территории «Бадары» с временным промежутком в один год (06/2016–06/2017). Коэффициент детерминации на тестовой выборке PWV( $k$ -БС) составил 0.86.

В рамках данной работы была сформирована общая выборка (включающая данные с территорий

Бадар, Шпицбергена, Чирага и Терскола), к которой была применена процедура снижения размерности. На массиве данных МИАП-2 со сниженной размерностью было проведено обучение модели  $k$ -БС, с разбиением на обучающую и тестовую выборки в соотношении 75% к 25% соответственно. В качестве параметров модели  $k$ -БС была использована евклидова метрика и количество соседей  $k = 3$ .

В работе метод  $k$ -БС применяется как вспомогательный для оценки порядка величины коэффициента детерминации  $R^2$  между исследуемыми данными. Кроме того, результаты применения метода  $k$ -БС могут использоваться для тестирования ИНС на переобучение (см. раздел 3.2.1). Далее результаты предсказания  $k$ -БС служат критериями минимально допустимых значений достоверности при использовании более сложных статистических моделей.


#### 3.2.1. Генерация искусственной выборки с помощью метода $k$ -ближайших соседей

Предсказательная способность нейронных сетей в значительной степени зависит от объема обучающих данных. Дополнение обучающей выборки искусственной может быть полезно в ситуации, когда объем исходных данных недостаточен. Помимо этого, искусственная выборка может быть полезной для тестирования статистических моделей на различных сценариях, в том числе на переобучение. Это позволяет оценить производительность модели в различных симулированных ситуациях и проверить ее устойчивость к разнообразным вариациям данных и способность обобщения.

Несмотря на то что продолжительность наблюдений в селе Чираг была больше, чем на Терсколе, из-за частичной неисправности прибора в течение сессий измерений эта выборка данных содержит меньше отсчетов. По этой причине тестовая выборка для территории Чирага была синтезирована с помощью метода  $k$ -БС. Также данная выборка служила для проверки переобучения модели.

### 3.3. Искусственная нейронная сеть

В качестве регрессионной статистической модели в работе используется искусственная нейронная сеть с топологией в виде цепи элементов, состоящей из полносвязных слоев и слоя с долговременной краткосрочной памятью (long short-term memory (LSTM), Hochreiter and Schmidhuber, 1997), представляющего собой подмножество нейронных сетей рекуррентного типа топологии (Recurrent neural network, RNN). LSTM-топологии используются для анализа временных рядов (Hochreiter and Schmidhuber, 1997; Shi et al., 2015).



**Рис. 1.** Функция потерь при обучении модели ИНС на совмещенной выборке. MAE — средняя абсолютная ошибка в мм. Линия 1: ошибка на обучающей выборке; штриховая линия 2: ошибка на тестовой выборке.

Топология ИНС составлена из шести слоев: входной слой с плотной связью (Dense), слой с долговременной краткосрочной памятью (LSTM) и четыре плотных слоя. Слои состоят из 350, 200, 17 500, 700, 10, 1 нейронов соответственно. Топология нейронной сети была выбрана эмпирически. В качестве функции активации для выходного слоя использовалась функция `softmax`, а для всех остальных — `Relu` (Asadi and Jiang, 2020). В качестве функции потерь была выбрана средняя абсолютная ошибка (Mean Absolute Error, MAE). ИНС реализована с помощью библиотеки `Keras` (Chicho and Bibo, 2021).

Выходным вектором при обучении ИНС являются значения напряжений с детектора. Входным вектором при обучении ИНС являются значения напряжений с детектора МИАП-2, которые предварительно прошли процедуру обработки.

Одной из проблем при обучении модели является ее переобучение. Оно ведет к тому, что ошибка обученного алгоритма на учебной выборке оказывается значительно ниже, чем ошибка на тестовой выборке. В результате достоверность предсказаний ИНС существенно ниже для любых данных, не входящих в выборку. Переобучение возникает при использовании избыточно сложных моделей или когда размер обучающей выборки недостаточен. Как следствие, аппроксимируются случайные особенности тренировочных данных, которые являются выбросами. Существуют различные подходы для избежания проблемы переобучения (Ying, 2019). В нашей работе используется функция ранней остановки (`EarlyStopping`, Prechelt, 1998). Она реализует автоматическую остановку обучения в случае, если в течение указанного количества эпох ошибка на тестовой выборке не уменьшается.

#### 4. РЕЗУЛЬТАТЫ

С помощью методов, которые описаны в разделе 3, мы провели анализ данных, полученных при наблюдениях в обсерваториях «Бадары», «Пик Терскол», на архипелаге Шпицберген и в селе Чирага (см. раздел 2).

Одной из целей работы являлась проверка достоверности данных MERRA-2 для Чирага. Была выполнена оценка обобщающей способности обученной модели на данных с места наблюдений, которое не было включено в тренировочную выборку. При обучении модели на данных, полученных в сессиях на территориях Бадар, Шпицбергена, Терскола, с использованием 134 эпох и при тестировании на данных Чирага коэффициент детерминации был равен 0.4. При этом на тестовых выборках данных Бадар, Шпицбергена и Терскола он составил 0.96, 0.96 и 0.90 соответственно. В дальнейшем модель повторно была обучена на данных из всех мест наблюдений, в том числе была учтена выборка данных из Чирага.

На рис. 1 представлен график функции логарифма потерь на обучающей и тестовой выборках во время обучения ИНС для 104 эпох. Коэффициент детерминации на тестовых выборках Бадар, Шпицбергена, Терскола и Чирага составил 0.97, 0.96, 0.91 и 0.9 соответственно (результаты представлены в таблице 2). При использовании метода  $k$ -БС коэффициент детерминации на тестовых выборках составил 0.87, 0.87, 0.69 и 0.81 соответственно.

Причина низкой предсказательной способности в данном случае может быть связана как с низкой обобщающей способностью модели, так и с разнородностью данных. Далее рассматриваются

**Таблица 2.** Коэффициент детерминации на валидационной выборке для моделей ИНС и  $k$ -БС

Место	$R^2$ (ИНС)	$R^2$ ( $k$ -БС)
Бадары	0.97	0.87
Шпицберген	0.96	0.87
Терскол	0.91	0.69
Чираг	0.90	0.81

результаты прогнозирования модели, обученной на данных со всех мест.

На рис. 2 представлены диаграммы рассеяния данных PWV(MERRA-2) и значений PWV, полученных с помощью статистических моделей ( $k$ -БС и ИНС). Как можно видеть, диаграммы рассеяния для значений PWV, полученных с помощью ИНС, демонстрируют меньший разброс по сравнению с  $k$ -БС. Таким образом, ИНС более пригодна, чем метод  $k$ -БС. Однако, в отличие от данных  $k$ -БС (рис. 2а,б), разброс точек ИНС (рис. 2с,д) различен для разных времен года. Так, для зимнего периода он является наибольшим, что свидетельствует об ухудшении предсказательной способности модели ИНС для этого времени. Данное ухудшение также можно наблюдать при сравнении временных рядов для летнего (рис. 3а) и зимнего (рис. 3б) периодов.

Для проверки ИНС на переобучение в рамках данной работы была осуществлена дополнительная валидация на искусственной выборке по измерениям в Чираге. Она строилась на основе данных MERRA-2 за два года (2017/01/01 – 2019/12/31), подробное описание генерации искусственной выборки дано в разделе 3.2.1. Коэффициент детерминации при дополнительной валидации составил 0.95, из чего следует, что искусственная нейронная сеть не была переобучена.

В рамках статьи был проведен сравнительный анализ различных оценок осажденных паров воды: PWV(РВП), PWV(GNSS) и PWV(MERRA-2) для обсерватории «Бадары». Графики зависимости между рассмотренными величинами приведены на рис. 4. Корреляция оценок PWV весьма значима, но на рис. 4б,с, которые представляют диаграммы рассеяния «PWV(РВП) – PWV(MERRA-2)» и «PWV(РВП) – PWV(GNSS)» соответственно, связь не является линейной для диапазона  $PWV < 1.5$  мм, что предполагает смещенность оценок.

На рис. 3 и 5 приведено сравнение прогнозируемых значений для территории «Бадар» с данными GNSS и РВП при использовании ИНС, обученной на выборке данных из четырех мест. Коэффициент детерминации между предсказаниями и данными

GNSS составил 0.96. Таким образом, предсказательная способность ИНС превышает полученную в работе Bubnov et al. (2021). Коэффициент детерминации  $R^2$  между данными PWV(ИНС) и PWV(РВП) равен 0.82 (см. рис. 5), что соответствует оценкам по MERRA-2 и РВП ( $R^2 = 0.82$ ).

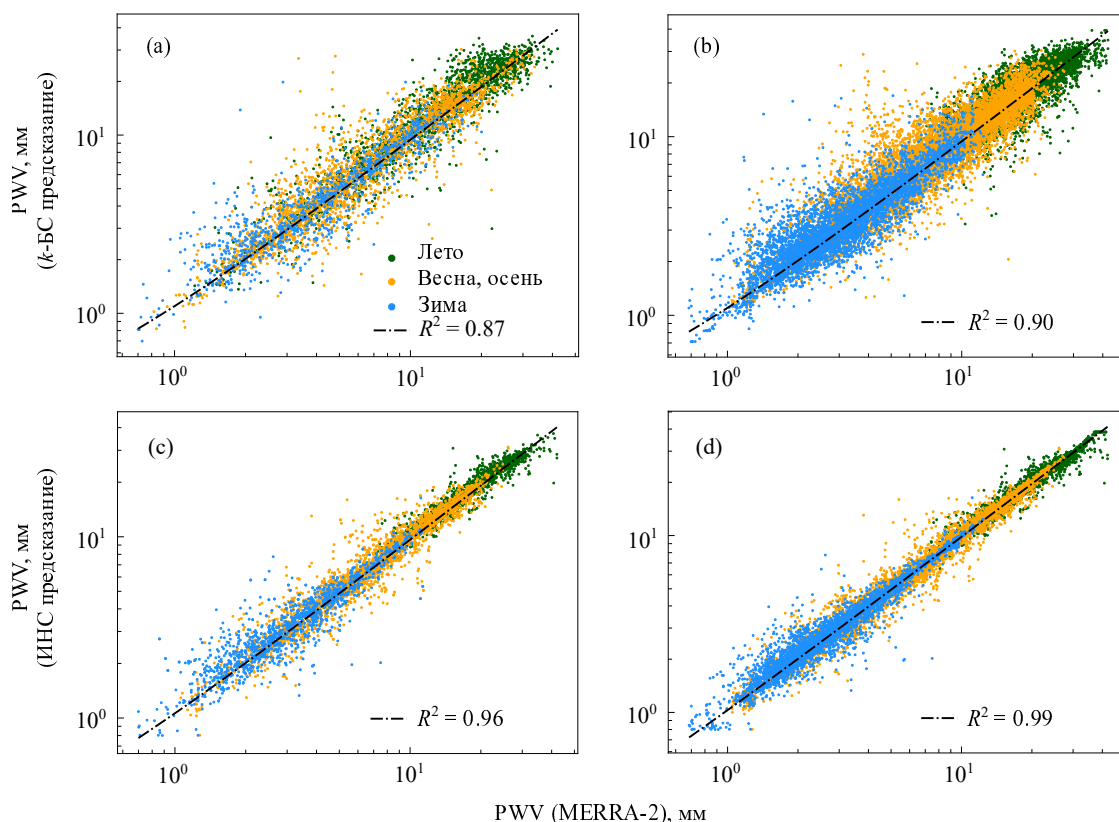
## 5. ОБСУЖДЕНИЕ ПОЛУЧЕННЫХ РЕЗУЛЬТАТОВ

Как видно из рис. 2, величины PWV для Бадар, Шпицбергена, Терскола и Чирага хорошо укладываются в регрессионную зависимость ( $R^2 = 0.99$  на всей выборке). Высокий коэффициент детерминации свидетельствует о применимости данного подхода, также как и близость прогнозируемых оценок и независимых измерений. Данный факт может быть подтвержден дополнительным расширением выборки за счет других мест, где проводились измерения МИАП-2. Однако имеется расхождение прогнозируемых значений PWV(РВП) с PWV(MERRA-2) и PWV(GNSS) при малых PWV (рис. 5). Оценки во всех случаях являются косвенными и требуют подтверждения прямыми измерениями. Малые величины PWV соответствуют наибольшей прозрачности атмосферы и наиболее важны при астрономических наблюдениях.

Интересен тот факт, что имеющихся данных по Терсколу недостаточно для построения статической модели, в том числе для  $k$ -БС ( $R^2 = 0.7$ ). Однако в случае обучения ИНС на всех четырех сессиях и валидации на тестовых данных Терскола значения коэффициента детерминации становятся существенно выше ( $R^2 = 0.9$ ). При этом необходимо отметить, что значение  $R^2 = 0.9$  все же меньше, чем для аналогичного случая для данных с территории «Бадар» и Шпицбергена ( $R^2 = 0.96$ ).

Эта ситуация может быть связана с тем, что в отличие от мест наблюдений на Шпицбергене и в обсерватории «Бадары», которые находятся на открытой местности, точка наблюдения в Терсколе располагалась в ущелье, в котором, вероятно, величина поглощения в приземном слое значительна, что не находит отражения в данных MERRA-2 в виду низкого разрешения последнего. Тем не менее коэффициент детерминации для валидационной выборки по данным Терскола достаточно высок, чтобы говорить о статистической значимости и, как следствие, об ограниченной применимости оценок MERRA-2 для данного места.

Как отмечалось выше, использование статистических моделей для данных МИАП-2 было предложено ранее Bubnov et al. (2021). Однако в этой работе целевое множество было сформировано на основе данных GNSS. На вход статистической




**Рис. 2.** Диаграммы рассеяния целевых величин осажженных паров воды (MERRA-2) относительно прогнозируемых значений: для тестовых подвыборок (а, с); для выборок, включающих тестовые и обучающие части (b, d). На панелях (а) и (b) представлены результаты прогноза по методу  $k$ -БС, на панелях (с) и (d) — результаты прогнозирования с помощью ИНС. Черная штрихпунктирная линия соответствует логарифму линии регрессии.  $R^2$  — коэффициент детерминации. Временные сезоны на диаграммах рассеяния выделены с помощью разных цветов. Голубым цветом показаны данные зимы, желтым цветом отображен весенне-осенний период, лето представлено зелеными точками.

модели подавалось временное окно с пятью наблюдениями подряд, что соответствует изменению состояния атмосферы за 50 минут. ИНС была составлена из двух слоев по 4800 и 192 нейронов, не считая входного и выходного. При этом для данных обсерватории «Бадары» коэффициент детерминации между предсказанными данными и GNSS составил 0.8.

В данной работе была использована более сложная топология нейронной сети (см. раздел 3.3) и расширена выборка за счет других мест наблюдений, что повысило достоверность предсказаний. В рассмотрение был включен слой с рекуррентностью, однако тестирование различными выборками не показало гистерезиса предсказаний при комбинировании тестовых выборок из разных данных. Вероятно, использование более сложной топологии и расширенной выборки позволило учесть аппаратные эффекты, которые смещали оценки и увеличивали разброс при использовании ИНС с меньшим количеством слоев. Возможно, что ИНС рекуррентных топологий менее чувстви-

тельна к шумам МИАП-2. Стоит отметить, что использование ИНС с топологией, описанной в разделе 3.3, позволило увеличить значение коэффициента детерминации в сравнении с простыми аппроксиматорами, такими как  $k$ -БС или ИНС с более простой топологией из работы Vibrov et al. (2021). Применение более сложной топологии позволило обобщить модель для разных мест наблюдений.

На основе результатов измерений в селе Чираг была показана применимость статистической модели, несмотря на неполноту измерений. Они охватывали зимний период, наиболее значимый для астрономии. Помимо этого был проведен анализ значений PWV за последние 10 лет по данным MERRA-2 (рис. 6). На графике представлены двумерные гистограммы, медианные значения и стандартные отклонения PWV по сезонам. Разброс значений за зимний период минимален. Медианные значения PWV равны 4.2 мм, 8.2 мм, 18.5 мм и 9.3 мм для зимы, весны, лета и осени соответственно.



**Рис. 3.** Графики временного ряда PWV по данным MERRA-2, полученным на основе GNSS, РВП и прогнозируемых ИНС из сессии измерений на территории «Бадар», выборка за один летний (а) и зимний (б) месяцы.

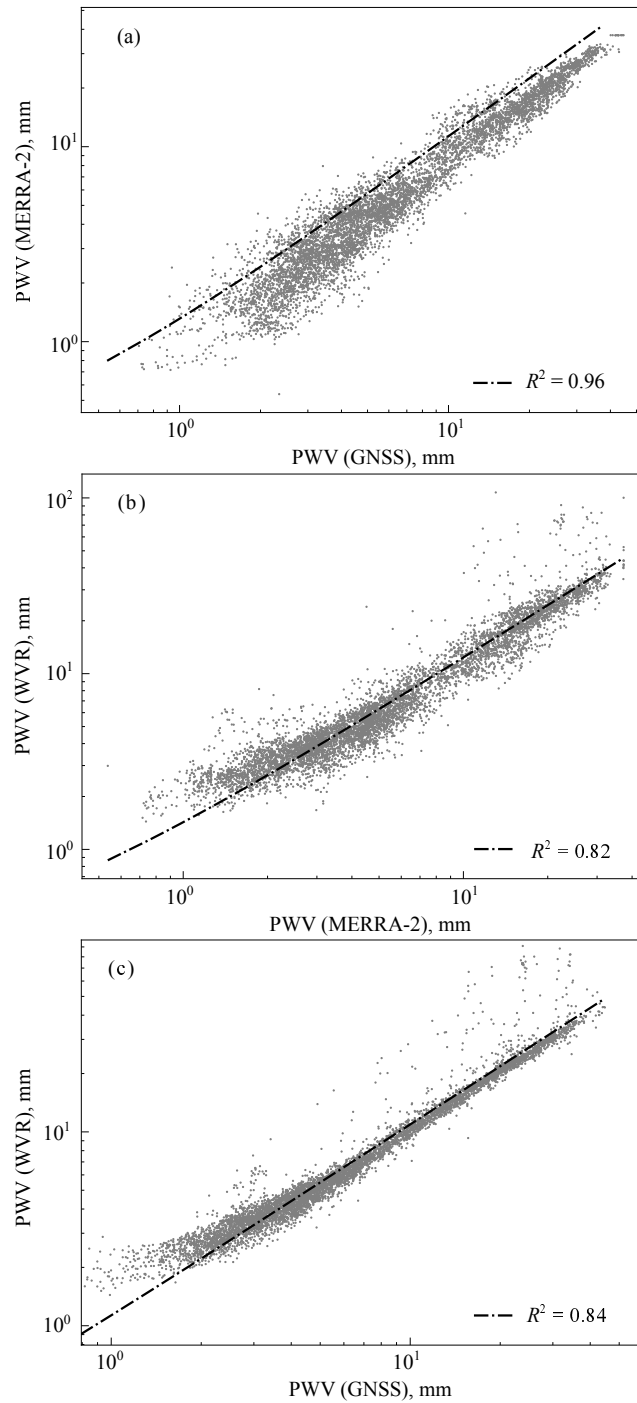
Стоит отметить, что восточная часть Северного Кавказа, и в том числе с. Чираг, имеет хорошие астроклиматические условия. В частности, существуют работы по изучению астроклимата на данной территории (Balega et al., 2022; Khaikin et al., 2022), в которых при анализе оптической толщины атмосферы в суб-ТГц диапазоне показана перспективность площадок на территории Дагестана.

Shikhovtsev et al. (2023) провели корреляционный анализ данных PWV с Терскола. Коэффициент корреляции между данными GNSS и ERA-5 был оценен в 0.71. При этом для других мест коэффициент детерминации был оценен выше (Хунзах, Дагестан — 0.94). Особенность данных с Терскола была также отмечена нами ранее в обсуждении полученных результатов. Если не рассматривать данные с Терскола, высокий коэффициент детерминации между данными GNSS и MERRA-2 (настоящая работа), GNSS и ERA-5 (Shikhovtsev et al., 2023) и вычисленными с помощью ИНС по МИАП-2 с MERRA-2 предполагает близость оце-

нок предсказаний ИНС и GNSS для большинства мест.

Расхождения оценок для Терскола свидетельствуют о том, что в ряде мест условия в атмосфере не соответствуют предполагаемым как при моделировании, так и по GNSS. Не существует исчерпывающих свидетельств того, что методики дают разные результаты. Нужно также учитывать, что смещение оценок в зависимости от методик может быть различным для разных мест исследований. Однако возможность использования ИНС с целевым множеством по MERRA-2 является косвенным свидетельством относительной однородности оценок PWV для разных мест. Дополнительная оценка методов нахождения PWV может быть произведена с помощью прямых измерений, например с аэростата, как погодных моделей так и других методов.

Сравнительный анализ, который провели Huang et al. (2021), показывает, что ERA-5 имеет чуть больший коэффициент корреляции (0.95) с данными GNSS по сравнению с коэффициентом



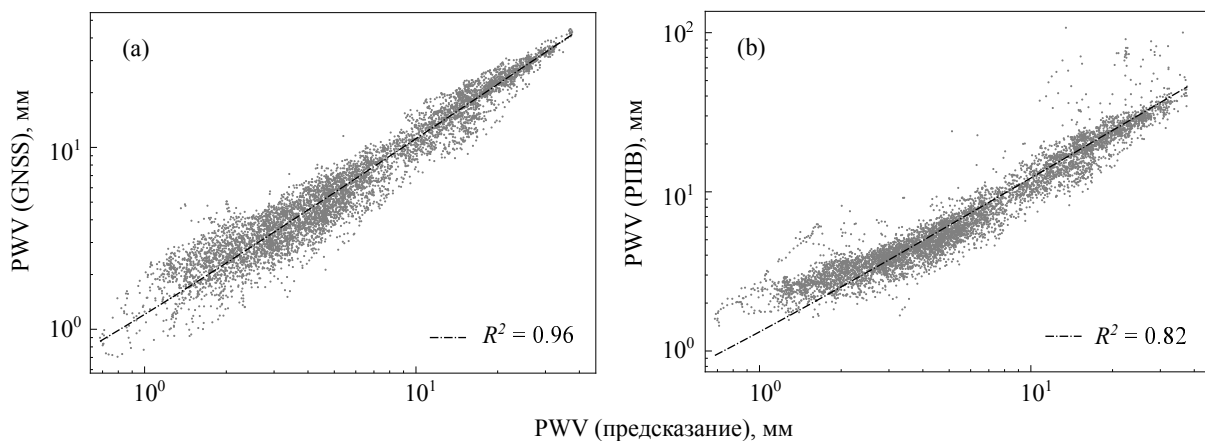
**Рис. 4.** Диаграммы рассеяния между парами данных PWV из различных источников для территории «Бадар». Черная штрихпунктирная линия отображает логарифм линии регрессии.  $R^2$  — коэффициент детерминации.

корреляции между значениями PWV MERRA-2 и GNSS (0.93). Большой коэффициент корреляции между данными GNSS и ERA-5, вероятно, связан с лучшим пространственным разрешением ERA-5 ( $0.25 \times 0.25$ ) по сравнению с MERRA-2 ( $0.5 \times 0.625$ ). Несмотря на высокий коэффициент корреляции, авторы статьи утверждают, что


надежность глобальных моделей должна быть тщательно проверена в условиях горного рельефа. Более низкий коэффициент корреляции для данных с Терскола (Shikhovtsev et al., 2023) и наши оценки подтверждают это.

При сравнительном анализе оценок оптической толщины в статье Bubukin et al. (2023) на основе





**Рис. 5.** Диаграммы рассеяния для тестовой подвыборки между прогнозируемыми значениям GNSS и РБП (а и б соответственно). Черная штрихпунктирная линия отображает регрессию для данных в логарифмической шкале.  $R^2$  — коэффициент детерминации.



**Рис. 6.** Двумерные гистограммы PWV (MERRA-2) для зимнего (а), весеннего (б), летнего (с) и осеннего (д) периодов для территории Чирага за десять лет.  $Q_2$  — медианные значения PWV; std — стандартное отклонение величины PWV.

глобального атмосферного моделирования НАСА и МИАП-2 на плато Суффа проиллюстрирована близость оценок, однако статистических характеристик сравнения приведено не было. Сравнительный анализ данных зондовых измерений PWV и PWV, рассчитанной из величины оптической толщины на основе измерений в 2-мм и 3-мм диапазонах МИАП-2, показывает сильное расхождение в результатах. Зондовые измерения приведены за другой временной период. Вычисления PWV на основе метода разрезов, измерений яркостных температур с помощью радиометров и из оценок оптических толщин весьма распространены, однако не лишены неопределенности. Оценки PWV по ИНС исключают промежуточное вычисление оптической толщины. Спектроскопические постоянные также не используются, что позволяет исключить неопределенность оценок, делая их, однако, зависимыми от смещения оценок ключевого множества. К сожалению, Vubukin et al. (2023) не привели сравнение PWV для зондовых измерений и результатов

моделирования атмосферы, что могло бы прояснить ситуацию со смещением оценок последнего.

## 6. ВЫВОДЫ

Нами был предложен подход к анализу наблюдательных данных для астроклиматических исследований, основанный на применении искусственных нейронных сетей с рекуррентной топологией. Метод применен для измерений радиометра МИАП-2 для разрезов, результаты измерений приведены к величинам PWV (MERRA-2). Существование такой статистической модели, в свою очередь, подтверждает правомерность оценок MERRA-2 для выбранных мест. Высокий коэффициент детерминации  $R^2 = 0.96$  при валидации на тестовых данных свидетельствует о высокой достоверности предсказаний. Оценки PWV для территории «Бадар», полученные с помощью статистической модели, хорошо согласуются с независимыми оценками GNSS и РБП (0.96 и 0.82 соответственно).

В статье были обработаны и проанализированы данные измерений радиометра в с. Чираг за 2022–2023 гг. Несмотря на то, что периодически из-за погодных и технических проблем прибор не работал, с помощью статистической модели показано, что данные MERRA-2 применимы к данному месту для анализа PWV.

Дальнейшее развитие нашей работы возможно как за счет применения климатических моделей с большим разрешением, таких как ERA-5, так и за счет увеличения объема данных радиометра МИАП-2, в том числе получаемых в рамках единого одновременного экспедиционного цикла с другими методами оценки, позволяющих исключить влияние на результат суточных и сезонных вариаций.

### БЛАГОДАРНОСТИ

Авторы выражают благодарность Г. Бубнову за помощь в поиске и анализе данных MERRA-2, а также за предоставление экспедиционных данных.

### ФИНАНСИРОВАНИЕ

Работа выполнена при поддержке гранта Российского научного фонда (грант РФФ № 23-22-00373).

### КОНФЛИКТ ИНТЕРЕСОВ

Авторы данной работы заявляют, что у них нет конфликта интересов.

### СПИСОК ЛИТЕРАТУРЫ

1. B. Asadi and H. Jiang, arXiv e-prints cs:2002.04060v1 (2020).
2. Y. Y. Balega, D.-S. Bataev, G. Bubnov, et al., *Doklady Physics* **67**, 1 (2022).
3. L. Bolbasova and V. Lukin, *Atmospheric and Oceanic Optics* **35** (3), 288 (2022). DOI:10.1134/S1024856022030022
4. G. Bubnov, <https://zenodo.org/records/4973548> (2021). DOI:10.5281/zenodo.5223928
5. G. Bubnov, P. Zemlyanukha, E. Dombek, and V. Vdovin, *J. Physics: Conf. Ser.*, **2015**, id. 012024 (2021). DOI:10.1088/1742-6596/2015/1/012024
6. G. M. Bubnov, V. F. Grigorev, V. F. Vdovin, et al., in *Proc. 30th International Symposium on Space Terahertz Technology (ISSTT 2019), Gothenburg, Sweden, 2019*, pp. 143–148.
7. G. M. Bubnov, V. F. Vdovin, V. Y. Bukov, et al., in *Proc. 2017 XXXIInd General Assembly and Scientific Symposium of the International Union of Radio Science (URSI GASS), Montreal, Canada, 2017*, p. 186. DOI:10.23919/URSIGASS.2017.8105000
8. I. Bubukin, I. Rakut, M. Agafonov, et al., *Radiophysics and Quantum Electronics* **65** (10), 719 (2023). DOI:10.1007/s11141-023-10252-0
9. B. T. Chicho and A. B. Sallow, *Journal of Soft Computing and Data Mining* **2** (2), 49 (2021). DOI:10.30880/jscdm.2021.02.02.005
10. T. Cover and P. Hart, *IEEE Transactions on Information Theory* **13** (1), 21 (1967). DOI:10.1109/TIT.1967.1053964
11. Global Modeling and Assimilation Office (GMAO): MERRA-2 inst1\_2d\_int\_Nx: 2d, 1-Hourly, Instantaneous, Single-Level, Assimilation, Vertically Integrated Diagnostics V5.12.4, Greenbelt, MD, USA, Goddard Earth Sciences Data and Information Services Center (GES DISC) (2015). DOI:10.5067/G0U6NGQ3BLE0
12. S. Hochreiter and J. Schmidhuber, *Neural Computation* **9**, 1735 (1997). DOI:10.1162/neco.1997.9.8.1735
13. L. Huang, Z. Mo, L. Liu, et al., *Earth and Space Science* **8** (5), e2020EA001516 (2021). DOI:10.1029/2020EA001516
14. A. Hyvärinen and E. Oja, *Neural Networks* **13** (4), 411 (2000). DOI:10.1016/S0893-6080(00)00026-5
15. G. Ilin, V. Bykov, V. Stempkovsky, and A. Shishikin, *Transactions of IAA RAS* **27** 210 (2013).
16. V. Khaikin, A. Y. Shikhovtsev, V. Shmagin, et al., *Zhurnal Radioelektroniki: Journal of Radio Electronics* **7**, 1684 (2022). DOI:10.30898/1684-1719.2022.7.9
17. A. G. Kislyakov and K. S. Stankevich, *Radiophysics and Quantum Electronics* **10** (9-10), 695 (1967). DOI:10.1007/BF01031599
18. O. Kramer, *Machine Learning for Evolution Strategies: Studies in Big Data* (Springer International Publishing, Switzerland, 2016), pp. 45–53. DOI:10.1007/978-3-319-33383-0
19. P. R. Merrifield, *American Educational Research Journal* **6** (3), 449 (1969). DOI:10.3102/00028312006003449
20. J. Milli, R. Gonzalez, P. R. Fluxa, et al., arXiv e-prints astro-ph/1910.13767 (2019). DOI:10.48550/arXiv.1910.13767
21. V. Nosov, O. Bolshakov, G. Bubnov, et al., *Instruments and Experimental Techniques* **59**, 374 (2016). DOI:10.1134/S0020441216020111
22. V. E. Panchuk and V. L. Afanasiev, *Astrophysical Bulletin* **66** (2), 233 (2011). DOI:10.1134/S199034131102009X
23. L. Prechelt, *Neural Networks: Tricks of the Trade* (Springer Berlin, Heidelberg, 1998), p. 55. DOI:10.1007/3-540-49430-8\_3
24. N. Ruzhentsev and A. Mihailov, *Natural Science* **2** 427 (2010). DOI:10.4236/ns.2010.25052
25. X. Shi, Z. Chen, H. Wang, et al., arXiv e-prints astro-ph/1506.04214 (2015). DOI:10.48550/arXiv.1506.04214

26. A. Y. Shikhovtsev, V. Khaikin, P. Kovadlo, and P. Baron, *Atmospheric and Oceanic Optics* **36** (1), 78 (2023). DOI:10.1134/S1024856023020148
27. M. E. Tipping and C. M. Bishop, *Journal of the Royal Statistical Society: Series B* **61** (3), 611 (1999). DOI:10.1111/1467-9868.00196
28. X. Ying, *Journal of Physics: Conference Series* **1168** (2), 022022 (2019). DOI:10.1088/1742-6596/1168/2/022022
29. F. N. Zakharov, S. A. Mikajlenko, and D. V. Timoshin, *Russian Physics Journal* volume **61** (3), 525 (2018). DOI:10.1007/s11182-018-1430-6

## Analysis of the Results of Astroclimate Measurements in the Millimeter Wavelength Range Using Machine Learning Methods

T. A. Khabarova<sup>1,2</sup>, P. M. Zemlyanukha<sup>1</sup>, E. M. Dombek<sup>2,1</sup>, A. S. Marukhno<sup>3</sup>, and V. F. Vdovin<sup>1,3,2</sup>

<sup>1</sup>Institute of Applied Physics RAS, Nizhny Novgorod, 603950 Russia

<sup>2</sup>Lobachevsky Nizhny Novgorod State University, Nizhny Novgorod, 603950 Russia

<sup>3</sup>Special Astrophysical Observatory, Russian Academy of Sciences, Nizhnii Arkhyz, 369167 Russia

This paper presents a method for estimating precipitable water vapor from radiometric data using machine learning methods. The results of a study of precipitated water vapor for the territory of Chirag (Dagestan), Terskol peak (Elbrus region), Badary observatory (Buryatia) and the Spitsbergen archipelago are presented. A comparative analysis of the assessment of precipitable water vapor for the territory of “Badary” was carried out using GNSS, MERRA-2, water vapor radiometer data and predicting values using machine learning methods based on data from the MIAP-2 microwave radiometer.

Keywords: *millimeter astronomy—methods: data analysis*