



ORIGINAL RESEARCH PAPER

Calibration of MODIS Water vapor data using multi-Layer perceptron neural network and radiosonde observations

K. Ghobadi¹, E. Javadnia^{*1}, H. Jalili², A. Zandkarimi²¹ Department of Geomatics Engineering, Faculty of Engineering, University of Zanjan, Zanjan, Iran² Iranian Space Research Center, Tehran, Iran

ABSTRACT

Received: 15 January 2025

Reviewed: 20 April 2025

Revised: 22 May 2025

Accepted: 31 May 2025

KEYWORDS:

Water Vapor

MODIS

Neural Network

Calibration

Radiosonde

* Corresponding author

✉ javadnia@znu.ac.ir

☎ (+9824) 33054504

Background and Objectives: Water vapor in the atmosphere is one of the most critical meteorological parameters, significantly influencing climate studies, weather forecasting, and climate change modeling. Precipitable Water Vapor (PWV) serves as a key indicator in atmospheric studies and is measured using satellite data, including Moderate Resolution Imaging Spectroradiometer (MODIS) sensor products. MODIS provides two PWV products: Near-Infrared (NIR), which is available only during the day, and Infrared (IR), which provides data for both day and night. Due to its broader temporal coverage, the IR product is widely utilized in various applications. However, the accuracy of this product, especially under varying atmospheric conditions during day and night, remains a major challenge. This study aims to enhance the accuracy of MODIS IR PWV data using machine learning and to assess the calibration's impact on day and night conditions.

Methods: This study utilized data from 10 radiosonde stations in Iran during the 2019-2020 period as reference ground-truth data. Three datasets were prepared: raw MODIS data, fitted data, and modified data. A Multi-Layer Perceptron (MLP) model was employed for calibration and to evaluate its performance for day and night data separately. Standard machine learning methods were applied to design and implement the model. The model's accuracy was evaluated using the Root Mean Square Error (RMSE) and correlation coefficient (R) metrics.

Findings: The results demonstrated that the MLP model significantly improved the accuracy of MODIS PWV data. During the day, RMSE decreased from 3.72 mm in the raw data to 2.63 mm in the calibrated model, while the correlation coefficient increased from 0.81 to 0.86. At night, RMSE reduced from 4.9 mm to 3.16 mm, and the correlation coefficient improved from 0.76 to 0.78. Overall, RMSE in raw MODIS data was 4.48 mm, which was reduced to 2.92 mm in the fitted model and 3.03 mm in the modified model. The correlation coefficient also improved from 0.77 to 0.87 and 0.85, respectively.

Conclusion: This study confirmed that the MLP model effectively enhances the accuracy of MODIS PWV data and reduces existing errors under different atmospheric conditions. The primary innovation of this research is the application of the MLP model to calibrate satellite-derived PWV data for day and night conditions. By improving the precision of satellite data, this method enhances its reliability for practical applications, particularly in weather forecasting and climate studies. Limitations include dependency on radiosonde data as the reference and the absence of analysis on specific atmospheric factors influencing modeling. This approach can also be extended in future studies to improve the accuracy of data from other satellite sensors.



NUMBER OF REFERENCES

41



NUMBER OF FIGURES

7



NUMBER OF TABLES

4

مقاله پژوهشی

کالیبراسیون داده‌های بخار آب سنجنده مودیس با استفاده از شبکه عصبی پرسپترون چندلایه و مشاهدات رادیوسوند

کمال قبادی^۱، اسلام جوادنیا^{۱*}، هادی جلیلی^۲، آرش زندکری^۲^۱ گروه مهندسی نقشه برداری، دانشکده مهندسی، دانشگاه زنجان، زنجان، ایران^۲ پژوهشگاه فضایی ایران، تهران، ایران

چکیده

پیشینه و اهداف: بخار آب موجود در جو یکی از مهم‌ترین پارامترهای هواشناسی است که تأثیر چشمگیری بر مطالعات اقلیمی، پیش‌بینی‌های جوی و مدل‌سازی‌های مرتبط با تغییرات آب‌وهوایی دارد. بخار آب قابل بارش (PWV) به‌عنوان شاخصی اساسی در بررسی وضعیت جوی، با استفاده از داده‌های ماهواره‌ای اندازه‌گیری می‌شود. داده‌های سنجنده طیفی تصویربرداری با توان تفکیک متوسط مودیس (MODIS)، شامل محصولات مادون قرمز نزدیک (NIR) و مادون قرمز (IR)، از جمله منابع اصلی اندازه‌گیری PWV هستند. محصول IR به دلیل ارائه داده در هر دو شرایط روز و شب، در بسیاری از مطالعات کاربرد دارد. با این حال، دقت این داده‌ها به‌ویژه در شرایط جوی مختلف روز و شب همچنان چالشی مهم باقی مانده است. هدف این پژوهش، بهبود دقت داده‌های IR PWV مودیس با استفاده از رویکرد یادگیری ماشین و بررسی تأثیر کالیبراسیون بر داده‌های روز و شب است.

روش‌ها: در این مطالعه، از داده‌های ۱۰ ایستگاه رادیوسوند در ایران طی دوره زمانی ۲۰۱۹-۲۰۲۰ به‌عنوان داده‌های مرجع استفاده شد. برای تحلیل، سه مجموعه داده شامل داده‌های اصلی مودیس، داده‌های برازش‌شده (fitting) و داده‌های اصلاح‌شده (modified) ایجاد شد. سپس مدل پرسپترون چندلایه (MLP) برای کالیبراسیون داده‌ها و مقایسه عملکرد آن در شرایط روز و شب به کار گرفته شد. این مدل با استفاده از روش‌های استاندارد یادگیری ماشین طراحی و توسعه یافت. ارزیابی دقت مدل با محاسبه معیارهای ریشه میانگین مربعات خطا (RMSE) و ضریب همبستگی (R) انجام شد.

یافته‌ها: نتایج نشان داد که مدل MLP توانست دقت داده‌های PWV مودیس را به طور قابل توجهی بهبود بخشد. در شرایط روز، RMSE از ۳/۷۲ میلی‌متر در داده‌های اصلی به ۲/۶۳ میلی‌متر کاهش یافت و ضریب همبستگی از ۰/۸۱ به ۰/۸۶ افزایش پیدا کرد. در شرایط شب، RMSE از ۴/۹ میلی‌متر به ۳/۱۶ میلی‌متر کاهش یافت و ضریب همبستگی از ۰/۷۶ به ۰/۷۸ بهبود یافت. در تحلیل کلی، RMSE داده‌های اصلی برابر با ۴/۴۸ میلی‌متر بود که در مدل برازش شده به ۲/۹۲ میلی‌متر و در مدل اصلاح‌شده به ۳/۰۳ میلی‌متر کاهش یافت. ضریب همبستگی نیز از ۰/۷۷ به ۰/۸۷ و از ۰/۸۵ افزایش یافت.

نتیجه‌گیری: این پژوهش نشان داد که مدل MLP توانایی بالایی در بهبود دقت داده‌های PWV مودیس دارد و می‌تواند خطاهای موجود در داده‌های این سنجنده را در شرایط مختلف جوی کاهش دهد. نوآوری اصلی این پژوهش، استفاده از مدل MLP برای کالیبراسیون داده‌های ماهواره‌ای در شرایط روز و شب است. این روش با بهبود دقت داده‌های ماهواره‌ای، قابلیت اطمینان آن‌ها را برای استفاده در پیش‌بینی‌های جوی و مطالعات اقلیمی افزایش می‌دهد. محدودیت‌های این مطالعه شامل وابستگی به داده‌های رادیوسوند به‌عنوان مرجع و عدم بررسی تأثیر عوامل جوی خاص بر مدل‌سازی است. این روش می‌تواند در مطالعات آینده برای بهبود دقت داده‌های سنجنده‌های دیگر نیز مورد استفاده قرار گیرد.

* نویسنده مسئول

javadnia@znu.ac.ir

۰۲۴-۳۳۰۵۴۵۰۴ (۱)

مقدمه

میلی‌متر، سانتی‌متر و یا اینچ بیان می‌شود [۱]. چنین ستون عمودی جو از سطح زمین آغاز و تا نقطه پایانی بخار آب در جو ادامه پیدا می‌کند. این پارامتر به‌شدت در مقیاس‌های مختلف مکانی و زمانی متغیر است و مقادیری از حدود ۸۰ میلی‌متر در نزدیکی استوا و کمتر از یک میلی‌متر در قطبین را به خود اختصاص می‌دهد [۲، ۳]. بخار آب از مهمترین گازهای گلخانه‌ای در جو زمین به شمار می‌رود و نقش کلیدی در چرخه آب، انتقال انرژی و تغییرات آب و هوایی دارد. به‌طور کلی، هر

به محتوای آب موجود در جو رطوبت گفته می‌شود که در سه فاز جامد، مایع و گاز موجود می‌باشد. فاز گازی رطوبت همان بخار آب است. پارامترهای مختلفی برای بیان میزان بخار آب جوی تعریف شده است که یکی از رایج‌ترین آن‌ها، بخار آب قابل بارش (Precipitable water Vapor -PWV) می‌باشد. ارتفاع مجموع بخار آب متراکم شده‌ی موجود در یک ستون عمودی جوی با سطح مقطع واحد را PWV گویند که برحسب

ادغام داده‌های مختلف استفاده کرده‌اند [۱۴]. با وجود نتایج قابل قبول، این روش‌ها معمولاً تنها بایاس کلی داده‌ها را اصلاح می‌کنند و قادر به درک تغییرات مکانی و زمانی بایاس نیستند، که این خود یکی از نقاط ضعف مهم در مطالعات پیشین محسوب می‌شود.

در سال‌های اخیر، استفاده از الگوریتم‌های هوش مصنوعی و یادگیری ماشین جهت اصلاح داده‌های ماهواره‌ای رشد چشمگیری داشته است. شبکه‌های عصبی و سایر تکنیک‌های یادگیری ماشین قادر به مدل‌سازی روابط پیچیده و غیرخطی بین داده‌های ورودی و خروجی هستند [۱۵]. در سالهای اخیر مطالعات مختلفی در خصوص بکارگیری تکنیک‌های یادگیری ماشین به منظور بهبود دقت داده‌های بخار آب ماهواره‌ای انجام گردیده است [۱۷-۲۱]. برای نمونه، ژیونگ و همکاران (۲۰۲۱) در چین با استفاده از داده‌های GNSS و چهار الگوریتم یادگیری ماشین به کالیبراسیون داده‌های NIR مودیس پرداختند [۱۹]. نتایج حاکی از کاهش چشمگیر خطاها و بهبود کیفیت داده‌های به دست آمده بود، به طوری که RMSE نهایی برای روش‌های مختلف در مقیاس سالانه بین ۳/۹ تا ۵ میلی‌متر و در مقیاس ماهانه بین ۲/۵ تا ۴/۶ میلی‌متر به دست آمد.

این مطالعات نشان داده‌اند که الگوریتم‌های یادگیری ماشین می‌توانند به خوبی برای تصحیح داده‌های ماهواره‌ای مورد استفاده قرار گیرند، به ویژه در مناطق با توپوگرافی پیچیده یا دسترسی محدود به داده‌های زمینی. در ایران نیز شرایط مشابهی وجود دارد؛ ناهمواری‌های زمین و اقلیم خشک، دستیابی به داده‌های دقیق را دشوار می‌سازند. با این حال، بهره‌گیری از روش‌های یادگیری ماشین برای بهبود دقت داده‌های IR مودیس که کمتر از NIR مورد توجه بوده، می‌تواند گام مهمی در ارتقای دقت مطالعات اقلیمی در کشور باشد.

برخلاف داده‌های NIR که تنها در روز در دسترس هستند و دقت بهتری دارند، داده‌های IR امکان پایش شبانه‌روزی را فراهم می‌کنند ولی دقت پایین‌تری دارند. این موضوع نیاز به تصحیح و کالیبراسیون دقیق‌تر برای داده‌های IR را دوجندان می‌سازد. در این پژوهش، از داده‌های رادیوسوند ده ایستگاه در نقاط مختلف ایران طی سال‌های ۲۰۱۹ تا ۲۰۲۰ به عنوان داده‌های هدف جهت آموزش شبکه عصبی استفاده شده است. هدف آن است که با بهبود داده‌های IR، بتوان درک بهتری از چرخه آب جوی به دست آورد.

نتایج چنین پژوهش‌هایی می‌تواند در ارتقای مدل‌سازی و پیش‌بینی دقیق‌تر آب‌وهوا در کشور مؤثر واقع شود. همچنین می‌تواند ابزار مفیدی برای سیاست‌گذاران در زمینه مدیریت منابع آب و آمادگی در برابر بلایای طبیعی فراهم کند. دقت بیشتر در اندازه‌گیری بخار آب می‌تواند در حوزه‌های متعددی نظیر تحقیقات اقلیمی، کشاورزی، ایمنی هوانوردی و مدیریت بحران نقش‌آفرین باشد. در نهایت، استفاده از تکنیک‌های پیشرفته یادگیری ماشین می‌تواند رویکردی نوین و مؤثر برای رفع محدودیت‌های گذشته و افزایش دقت داده‌های ماهواره‌ای در ایران ارائه دهد.

افزایش یک‌درجه‌ای دما می‌تواند باعث افزایش هفت درصدی محتوای آن شود، و افزایش بخار آب، به عنوان یک گاز گلخانه‌ای، گرمایش آب‌وهوا را تسریع می‌کند [۴]. بنابراین اندازه‌گیری دقیق داده‌های بخار آب برای مدل‌های پیش‌بینی آب و هوا، مطالعات اقلیمی و درک بهتر چرخه آب ضروری است.

رادیوسوند و سامانه موقعیت‌یابی جهانی (GNSS) به دلیل دقت بالای خود، به عنوان منابع مرجع در بسیاری از مطالعات شناخته می‌شوند. داده‌های رادیوسوند شامل اندازه‌گیری مستقیم رطوبت، دما و فشار است که برای محاسبه PWV حیاتی هستند. با این حال، این روش‌ها با محدودیت‌هایی چون رزولوشن زمانی پایین، عملکرد ضعیف در شرایط خاص جوی، هزینه‌های زیاد و پوشش مکانی نامنظم مواجه‌اند [۵]. در مقابل، GNSS با استفاده از اندازه‌گیری تأخیر سیگنال‌های ماهواره‌ای در هنگام عبور از جو، میزان PWV را به صورت غیرمستقیم تخمین می‌زند [۶]. هر دو روش زمینی دقت بالایی دارند، اما محدودیت‌هایی در پوشش مکانی و زمانی آن‌ها وجود دارد. در سوی دیگر، روش‌های سنجش از دور ماهواره‌ای امکان پوشش گسترده‌تر را فراهم می‌کنند و قابلیت مشاهده مناطق دورافتاده را دارند. با این حال، دقت این روش‌ها به عوامل مختلفی مانند شرایط جوی، ویژگی‌های سطح زمین و وجود ذرات معلق بستگی دارد [۷]. از این رو، عدم قطعیت این داده‌ها معمولاً بیشتر از روش‌های زمینی است [۸].


یکی از مهم‌ترین منابع داده‌های ماهواره‌ای در حوزه PWV، سنجنده مودیس (MODIS) روی ماهواره‌های ترا و آکوا است. مودیس با استفاده از باندهای مادون قرمز نزدیک (NIR) و مادون قرمز (IR)، امکان تولید محصولات بخار آب با قدرت تفکیک زمانی بالا را فراهم می‌سازد [۳، ۷]. داده‌های IR چهار بار و داده‌های NIR دو بار در روز در یک منطقه ثبت می‌شوند. با وجود گستره پوشش بالا، داده‌های ماهواره‌ای همچنان نیازمند ارزیابی و اصلاح در مقایسه با داده‌های دقیق زمینی هستند. به همین دلیل، مطالعات متعددی به مقایسه و اعتبارسنجی این داده‌ها با رادیوسوند و GPS پرداخته‌اند [۹-۱۱]. به عنوان مثال، لیو و همکاران (۲۰۱۵) با استفاده از داده‌های ۸۳ ایستگاه رادیوسوند در چین، دقت محصولات NIR و IR مودیس را مورد ارزیابی قرار دادند [۱۰]. نتایج نشان داد که هر دو محصول دارای خطای نسبی بالا هستند، اما محصول NIR دقت بهتری نسبت به IR دارد. نوروزی و جوادنیا (۱۴۰۰) نیز با استفاده از داده‌های GPS در زنجان طی سه سال، دقت محصول IR را بررسی کرده و به RMSE حدود ۳ میلی‌متر دست یافتند [۱۱]. این مطالعات اهمیت تصحیح داده‌های ماهواره‌ای به ویژه IR را که دقت کمتری دارد، نشان می‌دهند.

برای بهبود دقت داده‌های بخار آب ماهواره‌ای، روش‌های گوناگونی به کار گرفته شده‌اند. از جمله این روش‌ها می‌توان به برازش خطی با استفاده از داده‌های زمینی و درون‌یابی فضایی مانند کریجینگ و درون‌یابی فاصله وزنی اشاره کرد [۱۲، ۱۳]. همچنین، برخی مطالعات از مدل‌های پیچیده‌تری مانند هارمونیک‌های کروی و تخمین واریانس هلمرت برای

روش تحقیق

منطقه مطالعاتی و داده‌ها

ایران به دلیل قرار گرفتن در ناحیه خشک آسیا و تحت تأثیر بادهای شمال غربی، دارای آب‌وهوای نسبتاً خشک و گرم است. البته باید گفت که به دلیل وجود زمستان‌های سرد در مناطق مرتفع، همچنین دریای خزر و خلیج فارس، شرایط آب‌وهوایی در نواحی مختلف ایران متفاوت هستند [۲۲]. سرزمین ایران به شکل کلی، کوهستانی و میانگین بلندی آن، بیش از ۱۲۰۰ متر از سطح دریا می‌باشد. آب‌وهوا در این منطقه به دلیل تفاوت‌های عرض جغرافیایی، طول جغرافیایی و ارتفاع، پیچیده و متنوع است که منجر به تنوع در میزان بخارآب قابل بارش در منطقه تحقیقاتی می‌شود. رطوبت هوا در ایران به شدت متغیر و در مناطق مختلف کشور با توجه به شرایط محیطی و زمانی متفاوت است. در بسیاری از مناطق ایران، رطوبت هوا در فصول گرم به شدت پایین است و در نتیجه، شرایط آتش‌سوزی و خشک‌سالی در این فصل‌ها افزایش می‌یابد. در مناطقی که رطوبت هوا بیشتر است، به خصوص در شمال کشور، بارش بیشتری رخ می‌دهد و این مناطق دارای طبیعتی سرسبز و جنگلی هستند [۲۳]. شکل ۱، منطقه مورد مطالعه و نحوه پراکندگی ایستگاه‌های رادیوسوند در آن را نشان می‌دهد. نام ایستگاه‌های رادیوسوند مورد استفاده به همراه مشخصات جغرافیایی در جدول ۱ آورده شده است.



شکل ۱: منطقه مورد مطالعه و توزیع ایستگاه‌های رادیوسوند در آن
Fig. 1: Research area and distribution of Radiosondes stations

جدول ۱: مشخصات ایستگاه‌های رادیوسوند

Table 1: Specifications of radiosonde stations

Station Name	Station Coordinates	Station Elevation (m)	Station ID
OIII Tehran (Mehrabad)	35.68° N, 51.35° E	1191	40754
OIMB (Birjand)	32.86° N, 59.20° E	1491	40809
OIKK (Kerman)	30.25° N, 56.96° E	1754	40841
OIAW (Ahwaz)	31.33° N, 48.67° E	22	40811

داده‌های PWV

در این تحقیق دو مجموعه داده PWV مورد استفاده قرار گرفت. دسته اول داده‌های PWV استخراج شده از محصولات IR سنجنده مودیس است که با وجود فراوانی زیاد آن (چهار داده در شبانه‌روز) و دقت نسبتاً پایین آن در مقایسه با داده PWV سنتی محصول NIR، به عنوان داده هدف جهت کالیبراسیون و افزایش دقت بکار گرفته شد. بخش دوم شامل داده‌های PWV مشاهداتی در ایستگاه‌های هواشناسی مجهز به رادیوسوند است.

داده‌های PWV مودیس

محصولات بخارآب سطح دو از کالکشن ۶/۱ ماهواره آکوا (MYD05_L2) در این پژوهش مورد استفاده قرار گرفتند و از وبسایت <https://ladsweb.nascom.nasa.gov> با فرمت HDF برای منطقه مورد مطالعه و برای دوره زمانی ۲۰۱۹-۲۰۲۰ جمع‌آوری شدند. دلیل انتخاب داده‌های ماهواره آکوا در این پژوهش، تطابق زمانی آن‌ها با داده‌های رادیوسوند است که موجب افزایش همخوانی و دقت تحلیل‌ها می‌شود. سنجنده مودیس محصولات PWV مادون قرمز با قدرت تفکیک مکانی پنج کیلومتری را چهار بار و مادون قرمز نزدیک با قدرت تفکیک مکانی یک کیلومتری را دو بار در روز برای یک مکان ارائه می‌دهد. PWV باند مادون قرمز در ابتدا به عنوان یکی از محصولات MYD07 (پروفیل‌های اتمسفری مودیس) تولید شد و به منظور سهولت به محصولات بخارآب MYD05 اضافه گردید. الگوریتم بکار رفته در MYD07 توسط سیمین و همکاران (۲۰۰۳) از ۱۱ باند مادون قرمز (۲۵، ۲۷-۳۶) برای بازیابی مشخصات جوی دما و رطوبت، بخارآب قابل بارش، میزان کل ازن موجود و دمای سطح زمین استفاده می‌کند [۲۴]. پروفیل‌های دما و رطوبت مودیس در ۲۰ سطح تراز ارتفاعی تولید می‌شوند. بدین منظور یک الگوریتم بازیابی رگرسیون در شرایط آسمان صاف مورد استفاده قرار می‌گیرد، که در آن ضرایب رگرسیون با استفاده از یک مدل انتقال تابشی سریع با ویژگی‌های جوی گرفته‌شده از مجموعه داده‌های از پروفیل‌های جهانی (رادیوسوند و مدل) به دست می‌آیند. محصول بخارآب جوی، تخمینی از کل بخارآب ستون جوی است که از بازیابی یکپارچه مادون قرمز مودیس مربوط به پروفیل‌های رطوبت جوی در مناطق صاف و بدون ابر به دست می‌آید. این الگوریتم بازیابی، از داده‌های تابندگی (Radiance) اندازه‌گیری شده توسط سنجنده مودیس از زمین و اقیانوس استفاده می‌نماید [۲۵]. ارزیابی PWV باند IR با استفاده از مشاهدات

که نشان‌دهنده تغییرات گسترده این پارامتر در شرایط مختلف اقلیمی کشور است.

روش‌شناسی

در تحقیقات پیشین، تکنیک‌های یادگیری ماشین مختلفی در حوزه علوم زمین مورد استفاده قرار گرفته است. از جمله معروف‌ترین آن‌ها می‌توان به درخت تصمیم (DT)، ماشین بردار پشتیبان (SVM)، جنگل تصادفی (RF)، الگوریتم نزدیکترین همسایه (KNN) و شبکه‌های عصبی مصنوعی (ANN) اشاره کرد [۳۰-۳۲]. این تکنیک‌ها برای کاربردهایی مانند پیش‌بینی مخاطرات طبیعی، تحلیل الگوهای اقلیمی، بررسی تغییرات کاربری زمین، و تحلیل داده‌های سنجش از دور به کار رفته‌اند. از بین این الگوریتم‌ها، معمولاً RF و ANN بیشترین دقت و کارایی را در تحلیل داده‌های پیچیده و چندبعدی علوم زمین داشته‌اند [۳۲-۳۴]. جنگل تصادفی به دلیل ساختار ترکیبی و توانایی در کاهش بیش‌برازش (Overfitting) و شبکه‌های عصبی مصنوعی به دلیل قابلیت تشخیص الگوهای پیچیده، به‌ویژه در مسائل پیش‌بینی و طبقه‌بندی، عملکرد بهتری داشته‌اند [۳۵]. در این مقاله ANN به‌منظور کالبراسیون داده‌های بخار آب مودیس استفاده شد. متناسب با صورت مسئله تحقیق، شبکه عصبی پرسپترون چند لایه (Multi-Layer Perceptron- MLP) انتخاب گردید. در ادامه جزئیات الگوریتم MLP توضیح داده خواهد شد.

شبکه عصبی پرسپترون چندلایه

شبکه عصبی پرسپترون چندلایه (MLP) شامل لایه ورودی، یک یا چند لایه مخفی و لایه خروجی است. در این شبکه، هر نورون به نورون‌های لایه بعد متصل است، و هر اتصال دارای یک وزن است که مقدار آن در طول آموزش تنظیم می‌شود تا مدل به دقت بالاتری دست یابد [۳۶].

ساختار و روابط شبکه عصبی MLP

○ لایه ورودی: در شبکه عصبی، لایه ورودی شامل نودهایی است که هر کدام یک ویژگی از داده‌های ورودی را نشان می‌دهد. به‌عنوان مثال، اگر داده ورودی شامل طول و عرض جغرافیایی، ارتفاع، زمان و مقدار بخار آب سنجنده مودیس باشد، این لایه شامل ۵ نود (ویژگی) خواهد بود.
○ لایه‌های مخفی: این لایه‌ها با استفاده از روابط غیرخطی و وزن‌های تنظیم‌شده، ویژگی‌های پیچیده‌تری را از ورودی استخراج می‌کنند. هر نود در یک لایه مخفی جمع وزنی ورودی‌های خود را به‌علاوه یک بایاس دریافت می‌کند. این مجموع سپس از یک تابع فعال‌سازی غیرخطی عبور می‌کند. یکی از رایج‌ترین توابع فعال‌سازی در این لایه‌ها، ReLU است که رابطه آن به‌صورت زیر است [۳۷].

$$g(x) = \frac{2}{1 + \exp(-2x)} - 1 \quad (4)$$

این تابع صفرمحور است و به مدل کمک می‌کند تا مقادیر ورودی منفی، خنثی و مثبت داشته باشد؛ به عبارت دیگر، مقادیر منفی، به‌شدت منفی

زمینی توسط سیمین و همکارانش (۲۰۰۸) انجام شد. نتایج به‌دست‌آمده نشان داد که RMSE این داده‌ها برابر ۱/۴ میلی‌متر در مقایسه با رادیومتر مایکروویو می‌باشد.

داده‌های PWV رادیوسوند

رادیوسوندها از ابزارهای مهم اندازه‌گیری برای اندازه‌گیری دما، رطوبت، فشار، سمت و سرعت باد در جو بالا هستند. این ابزار اندازه‌گیری توسط بالون‌های هواشناسی به اعماق جو ارسال شده و وظیفه دیده‌بانی از سطوح فوقانی جو را انجام می‌دهد. بر اساس طراحی بالن مانند رادیوسوند، می‌توان به‌طور مستقیم پارامترهای جوی مانند فشار، دما و رطوبت نسبی را در ارتفاع‌های مختلف اندازه‌گیری کرد [۲۶-۲۸].

اگر q رطوبت ویژه یا نسبت آمیختگی برحسب گرم بخار آب بر کیلوگرم هوا باشد آنگاه بخار آب قابل بارش برحسب میلی‌متر که در یک‌لایه محدودشده با فشارهای p_1 و p_2 قرار دارد، به‌صورت رابطه ۱ تعریف می‌شود:

$$PWV = \frac{1}{g} \int_{p_1}^{p_2} q \, dp \quad (1)$$

که در آن g شتاب جاذبه زمین برحسب متر بر مجذور ثانیه، p_1 فشار در سطح زمین و p_2 فشار در بالای جو زمین برحسب پاسکال می‌باشد. رطوبت ویژه با استفاده از معادله ۲ محاسبه می‌شود [۲۷]:

$$q = \frac{0.622e_s}{p - e_s} \quad (2)$$

که در آن e_s فشار جزئی اشباع بخار آب و p فشار هوا می‌باشند. e_s فشار جزئی اشباع بخار آب برحسب پاسکال را می‌توان با استفاده از رابطه ۳ محاسبه نمود:

$$e_s = 6.112 \exp\left(\frac{17.67T_d}{T_d + 243.15}\right) \quad (3)$$

T_d دمای نقطه‌ی شبنم برحسب درجه سانتی‌گراد می‌باشد [۲۹].

در این پژوهش از ایستگاه‌های رادیوسوند در شهرهای تهران، اصفهان، شیراز، اهواز، زاهدان، کرمان، بیرجند، تبریز، کرمانشاه و مشهد استفاده‌شده که از میان آن‌ها تنها در ایستگاه مهرآباد تهران دو بار پرتاب بالون رادیوسوند و در نتیجه دو داده بخار آب قابل بارش در شبانه‌روز وجود دارد. ایستگاه‌های اهواز، بیرجند، کرمان فقط در روز و ایستگاه‌های اصفهان، شیراز، مشهد، زاهدان، کرمانشاه و تبریز فقط در شب داده دارند. داده‌های رادیوسوند به شکل آنلاین برای ایستگاه‌های فعال در سرتاسر دنیا در پایگاه دانشگاه ویومینگ موجود و قابل استفاده است (<http://weather.uwyo.edu/upperair/sounding.html>). لذا

داده‌های موجود در این پایگاه طی سال‌های ۲۰۱۹-۲۰۲۰ به‌عنوان داده‌های هدف برای آموزش شبکه عصبی استخراج شدند. در جدول شماره ۱، اسامی ایستگاه‌های رادیوسوند به‌کاررفته همراه با ویژگی‌های جغرافیایی آن‌ها آورده شده است. بر مبنای ایستگاه‌های مطالعاتی این تحقیق، محدوده تغییرات PWV در ایران بین ۱/۴ تا ۴۶/۲ میلی‌متر است

فرایند آموزش مدل

در فرایند آموزش، هدف این است که خطای بین خروجی شبکه و مقدار واقعی به حداقل برسد. این کار با استفاده از الگوریتم پس انتشار خطا (Backpropagation) انجام می شود که به صورت زیر عمل می کند [۳۹]:

- محاسبه خطا: ابتدا مقدار خطا (تفاوت بین پیش بینی و مقدار واقعی) با استفاده از یک تابع هزینه محاسبه می شود. برای مثال، اگر از میانگین مربعات خطا (MSE) استفاده شود، رابطه به صورت زیر خواهد بود:

$$MSE = \sum_{i=1}^n \frac{1}{N} (y_i - \hat{y}_i)^2 \quad (7)$$

که y_i مقدار واقعی و $\hat{y}_i$ مقدار پیش بینی شده است.

- انتشار خطا و تنظیم وزن ها: خطا از لایه خروجی به سمت لایه های قبلی منتشر می شود و وزن ها با استفاده از گرادینت کاهشی (Gradient Descent) و الگوریتم های بهینه سازی مانند Adam به روز رسانی می شوند [۴۰].

مراحل انجام تحقیق

در این پژوهش، هدف کالیبراسیون داده های بخار آب سنجنده مودیس با استفاده از شبکه عصبی MLP و مشاهدات رادیوسوند است. داده های بخار آب از سنجنده مودیس و رادیوسوند به عنوان ورودی و خروجی به مدل شبکه عصبی وارد می شوند تا دقت برآورد بخار آب سنجنده مودیس بهبود یابد. مراحل کلی انجام کار به صورت شکل ۲ است که در بخش های بعدی مراحل به تفکیک توضیح داده می شود:

و مقادیر صفر در گراف تانژانت هایپربولیک نزدیک به صفر نگاشت می شوند [۳۸] و به شبکه کمک می کند تا ویژگی های پیچیده تری را یاد بگیرد.

○ لایه خروجی: این لایه مقدار خروجی پیش بینی شده توسط شبکه را ارائه می دهد. اگر خروجی یک مقدار پیوسته باشد (مانند پیش بینی بخار آب)، تابع فعال سازی لایه خروجی می تواند خطی باشد. در غیر این صورت، می توان از تابع سیگموئید یا تانژانت هایپربولیک برای خروجی های دسته بندی شده استفاده کرد.

روابط ریاضی در شبکه عصبی

فرض کنیم که x بردار ورودی (مثلاً شامل طول جغرافیایی، عرض جغرافیایی، ارتفاع و...) و y خروجی واقعی باشد. هر نود در یک لایه مجموع وزنی ورودی ها را محاسبه کرده و از طریق تابع فعال سازی عبور می دهد. فرمول ریاضی برای محاسبه خروجی هر نود به شرح زیر است:

- جمع ورودی ها: اگر $x_1, x_2, \dots, x_n$ ورودی ها و $w_1, w_2, \dots, w_n$ وزن های مرتبط با هر ورودی باشند، جمع وزنی به صورت زیر محاسبه می شود:


$$z = \sum_{i=1}^n x_i w_i + b \quad (5)$$

○ که b یک مقدار بایاس است.

○ تابع فعال سازی: خروجی این نود که به صورت a نشان داده می شود، با اعمال تابع فعال سازی به z محاسبه می شود:

$$f(z) = a \quad (6)$$

○ پیش بینی نهایی: پس از عبور از لایه های مختلف، مقدار نهایی که شبکه عصبی به عنوان پیش بینی ارائه می دهد از لایه خروجی به دست می آید.



شکل ۲: یک نمایش شماتیک از مراحل انجام تحقیق

Fig. 2: A schematic representation of the steps involved in this study

جمع‌آوری داده‌ها

در این پژوهش، داده‌های بخار آب سنجنده مودیس به‌عنوان داده‌های ورودی مدل مورد استفاده قرار گرفته است. همچنین از مشاهدات رادیوسوند به‌عنوان داده‌های مرجع (Ground Truth) برای کالیبراسیون استفاده شده است. برای هر موقعیت جغرافیایی و زمانی خاص، داده‌های زیر به‌عنوان ورودی به مدل شبکه عصبی داده می‌شود: طول جغرافیایی (Longitude)، عرض جغرافیایی (Latitude)، ارتفاع (Altitude)، زمان (Time) و بخار آب قابل بارش مودیس (MODIS PWV).

پیش‌پردازش داده‌ها

برای افزایش دقت و کارایی مدل، مراحل پیش‌پردازش داده‌ها به‌صورت زیر انجام شد:

○ نرمال‌سازی: مقادیر ورودی شامل طول و عرض جغرافیایی، ارتفاع، زمان و بخار آب سنجنده مودیس به مقادیر بین ۰ تا ۱ نرمال‌سازی شدند تا یادگیری مدل بهبود یابد.

○ جفت‌سازی داده‌ها: داده‌های مودیس و مشاهدات رادیوسوند در نقاط زمانی و مکانی یکسان مطابقت داده شدند. برای هر نمونه از داده‌های مودیس یک مقدار متناظر از بخار آب قابل بارش از مشاهدات رادیوسوند به‌عنوان خروجی هدف (Target Output) تعیین شد.

طراحی مدل شبکه عصبی

برای کالیبراسیون داده‌های مودیس از یک شبکه عصبی MLP استفاده شد. این شبکه عصبی به‌گونه‌ای طراحی شد که بتواند رابطه غیرخطی بین ورودی‌ها و خروجی‌ها را یاد بگیرد. ساختار مدل شبکه عصبی به شرح زیر است:

○ لایه ورودی (Input Layer): این لایه شامل ۵ نود است که هر نود با یکی از ورودی‌های مدل (طول و عرض جغرافیایی، ارتفاع، زمان و بخار آب مودیس) مرتبط است.

• لایه‌های مخفی (Hidden Layers): برای بهینه‌سازی دقت مدل، تعداد لایه‌های مخفی و تعداد نودهای هر لایه با استفاده از روش جستجوی شبکه (Grid Search) تعیین شد. این روش به‌صورت سیستماتیک پارامترهای مختلف را بررسی کرده و بهترین ترکیب را برای دستیابی به بالاترین دقت انتخاب می‌کند. در هر لایه مخفی از تابع فعال‌سازی تانژانت هائپربولیک استفاده شد.

• لایه خروجی (Output Layer): این لایه شامل یک نود است که مقدار تخمینی بخار آب قابل بارش را ارائه می‌دهد. در اینجا از تابع فعال‌سازی غیرخطی استفاده شده است.

آموزش مدل

مدل شبکه عصبی با استفاده از داده‌های آموزش که شامل ورودی‌های مودیس و خروجی‌های متناظر رادیوسوند بود، آموزش داده شد.

○ تابع هزینه (Loss Function): برای ارزیابی خطا، از میانگین مربعات خطا (MSE) به‌عنوان تابع هزینه استفاده شد.

○ الگوریتم بهینه‌سازی: از الگوریتم Adam برای بهینه‌سازی وزن‌های مدل استفاده گردید. این الگوریتم به دلیل قابلیت تطبیق خودکار نرخ یادگیری در طول آموزش، باعث سرعت و پایداری در یادگیری مدل می‌شود.

○ پارامترهای آموزشی: مدل با یک نرخ یادگیری بهینه و تعداد مناسب تکرارهای آموزشی (epoch) تنظیم شد تا به دقت مطلوب برسد و از بیش‌برازش جلوگیری شود.

ارزیابی مدل

در این تحقیق، برای ارزیابی عملکرد مدل از روش اعتبارسنجی متقابل ۱۰-تایی (10-fold) استفاده شد [۴۱]. بدین صورت که داده‌های موجود به ۱۰ بخش تقسیم شدند و در هر تکرار، ۹ بخش از داده‌ها به‌عنوان داده‌های آموزش و یک بخش به‌عنوان داده تست انتخاب شدند. این فرآیند ۱۰ بار تکرار شد به‌گونه‌ای که هر بخش داده‌ها یک‌بار به‌عنوان داده تست استفاده شد. میانگین معیارهای ارزیابی به‌دست‌آمده از ۱۰ تکرار به‌عنوان نتیجه نهایی ارزیابی مدل در نظر گرفته شد. این روش ارزیابی کمک می‌کند تا از بیش‌برازش جلوگیری شود و مدل توانایی تعمیم‌پذیری بهتری بر روی داده‌های جدید پیدا کند. شاخص‌های ارزیابی دقت مدل در هر تکرار شامل جذر میانگین مربعات خطا (RMSE)، بایاس (Bias) و ضریب همبستگی (R) می‌باشد.

تحلیل نتایج و بهینه‌سازی

مدل به‌منظور افزایش دقت با تغییر تعداد لایه‌ها و نودها تنظیم شد و مقادیر شاخص‌های ارزیابی به‌دست‌آمده با نتایج دیگر روش‌های موجود مقایسه شد. همچنین، مدل برای مکان‌ها و زمان‌های مختلف کالیبره شد تا عملکرد آن در شرایط مختلف آب‌وهوایی و جغرافیایی بررسی شود.

پردازش داده‌ها

داده‌های بخار آب قابل بارش (PWV) موردنیاز این پژوهش از محصولات سنجنده مادون قرمز مودیس ماهواره آکوا استخراج شده‌اند. برای این منظور، تصاویر روزانه MYD05 مربوط به سنجنده مودیس که شامل اطلاعات بخار آب، پوشش ابر، و ویژگی‌های جوی هستند، دریافت و به نرم‌افزار ENVI وارد شدند. با استفاده از افزونه MCTK، لایه اطلاعاتی MODIS PWV IR استخراج و زمین‌مرجع گردید. در مرحله بعد، مقادیر PWV برای بازه زمانی موردنظر در ایستگاه‌های مطالعاتی استخراج شد. پس از استخراج مقادیر PWV از تصاویر ماهواره‌ای مودیس، داده‌های روزهای ابری شناسایی و حذف شدند، زیرا حضور ابرها می‌تواند دقت برآورد بخار آب توسط الگوریتم مادون قرمز مودیس را کاهش دهد. به این منظور، از محصول ماسک ابر مودیس با نام MYD35 استفاده شد و روزهای ابری از مجموعه داده‌ها حذف گردیدند. همچنین، داده‌ها یا تصاویری که ایستگاه‌های رادیوسوند را شامل می‌شدند اما مقادیر NAN


میانگین تفاوت داده‌های بخار آب قابل بارش از این دو منبع را نشان می‌دهد.

تعیین هایپرپارامترها

باید محدوده مشخصی از مقادیر مختلف برای پارامترها توسط تابع GridsearchCV بر روی داده‌ها تست و اجرا شوند تا مقادیر بهینه برای الگوریتم‌ها به دست آیند. مقدار بهینه تعداد لایه‌های پنهان در محدوده ۵ تا ۱۲ در نظر گرفته شد. به طریق مشابه، جهت تعیین بهترین پارامتر نرخ یادگیری به منظور به حداقل رساندن سرعت همگرایی الگوریتم مقادیر مختلف در محدوده ۰/۰۰۰۱ تا ۰/۱ به صورت لگاریتمی انتخاب شد. به دلیل اینکه مقدار بهینه نرخ یادگیری ممکن است در چندین مرتبه تغییر کند، لذا انتخاب یک محدوده خطی از مقادیر ممکن است مؤثر واقع نشود. استفاده از فضای لگاریتمی به جای فضای خطی، به ما اجازه می‌دهد بهترین مقدار را برای نرخ یادگیری با سرعت و دقت بیشتری یافت شود. در شکل ۴ خطای پیش‌بینی در بازه ۰/۱ تا ۰/۱۰۰۱ برای این فرا پارامتر نمایش داده شده است. بر اساس نتایج اعتبارسنجی متقابل، بهترین مقدار نرخ یادگیری حدود ۰/۰۱۶، و بهترین تعداد لایه‌های پنهان ۸، و در نهایت مقدار پارامتر لامبدا در تنظیم L2 جهت جلوگیری از بیش برازش مقدار ۰/۰۵ انتخاب شد.


داشتند نیز از مجموعه داده‌ها حذف شدند. علاوه بر داده‌های بخار آب ماهواره‌ای، داده‌های مرجع PWV رادیوسوند نیز برای ایستگاه‌های منتخب از وبسایت آرشیو ملی مرکز پیش‌بینی محیطی دانشگاه وایومینگ دانلود شدند. سپس با استفاده از نرم‌افزار اکسل، داده‌های رادیوسوند بر اساس زمان و موقعیت مکانی با داده‌های بخار آب مودیس تطبیق داده شدند تا جفت داده‌های مکانی - زمانی مشترک از هر دو منبع داده به دست آید. این جفت داده‌ها به عنوان مبنای مقایسه و ارزیابی دقت محصولات بخار آب قابل بارش مودیس مورد استفاده قرار گرفتند. در نهایت، پس از جمع‌آوری و تطبیق داده‌های بخار آب مودیس و داده‌های رادیوسوند، کلیه داده‌ها به فرمت CSV ذخیره شدند تا در محیط برنامه‌نویسی پایتون قابل استفاده باشند.

در قدم بعدی تفاوت بین داده‌های مودیس و رادیوسوند را با استفاده از جفت‌های نمونه به دست آمده محاسبه شده و برای تبعیت از توزیع نرمال ارزیابی می‌شوند که بدین منظور انحراف معیار σ اختلاف‌های به دست آمده را محاسبه و از 3σ به عنوان آستانه برای حذف داده‌های پرت استفاده می‌شود. پس از بررسی، ۴۰۱۳ نمونه مودیس - رادیوسوند مربوط به سال‌های ۲۰۱۹ و ۲۰۲۰ برای ساخت مدل‌های پرسپترون چندلایه و جنگل تصادفی مورد استفاده قرار گرفتند. در شکل ۳ چگونگی حذف این نوع داده‌ها مشاهده می‌شود. خطوط قرمز در هر دو شکل، آستانه تفاوت داده‌ها یعنی $\pm 3\sigma$ و خط سبز در شکل سمت چپ،



شکل ۳: تفاوت بین داده‌های بخار آب قابل بارش مادون قرمز سنجنده مودیس (آکوا) با داده‌های بخار آب رادیوسوند به همراه هیستوگرام
Fig. 3: Difference between MODIS IR PWV (AQUA) data and radiosonde water vapor data, along with its histogram

این منظور داده‌های سال‌های ۲۰۱۹ و ۲۰۲۰ به‌منظور آموزش مدل استفاده شدند. دقت برازش (Fitting) مدل (دقت روی داده‌های آموزشی) و دقت اصلاح‌شده (Modified) مدل (دقت اعتبارسنجی متقابل) به همراه دقت داده‌های اصلی در جدول ۳ نمایش داده شده است.



شکل ۵: دیاگرام پراکنش داده‌های اصلی مودیس آکوا در مقایسه با داده‌های بخار آب مشاهداتی رادیوسوند (۲۰۱۹-۲۰۲۰)


Fig. 5: Comparison of MODIS IR PWV-Aqua Data with Radiosonde-Observed Precipitable Water Vapor (2019-2020)

جدول ۳: نتایج عملکرد الگوریتم شبکه عصبی MLP بر روی داده‌های بخار آب مودیس آکوا و در مقایسه با مقادیر استخراج شده در ۱۰ ایستگاه رادیوسوند (۲۰۱۹-۲۰۲۰)

Table 3: Performance Results of the MLP Neural Network Algorithm on MODIS IR PWV-Aqua Data Compared to Radiosonde Observations

Model		Bias (mm)	RMSE (mm)	STD (mm)	R
Original		-0.37	4.44	4.42	0.78
Multi-Layer Perceptron (MLP)	Fitting	0.00	2.83	2.83	0.88
	Modified	0.01	2.91	2.91	0.87

چنانچه ملاحظه می‌گردد، دقت داده‌های اصلی دقت اولیه داده‌های بخار آب بدون کالیبراسیون یا اصلاح است. ضریب همبستگی (R) برابر با ۰/۷۸ است که نشان می‌دهد بین داده‌های اصلی و مقادیر واقعی همبستگی متوسطی وجود دارد. پس از استفاده از مدل شبکه عصبی MLP برای داده‌های آموزشی، دقت برازش مدل بهبود یافته است. کاهش RMSE به ۲/۸۳ و افزایش ضریب همبستگی به ۰/۸۸ نشان‌دهنده بهبود عملکرد مدل روی داده‌های آموزشی است. مقدار Bias نزدیک به صفر است که نشان‌دهنده عملکرد خوب مدل در یادگیری داده‌های آموزشی است. نتایج مدل اصلاح‌شده نیز نشان‌دهنده دقت مدل روی داده‌های جدید است که از طریق روش اعتبارسنجی متقابل به‌دست‌آمده است. کاهش RMSE نسبت به داده‌های اصلی (به ۲/۹۱) و ضریب همبستگی ۰/۸۷ نشان می‌دهد مدل توانسته است به‌خوبی روی داده‌های جدید عمل کند، هرچند این دقت کمی کمتر از داده‌های آموزشی است. مقدار Bias به



شکل ۴: خطای الگوریتم شبکه عصبی پرسپترون چندلایه (MLP) برای مقادیر مختلف نرخ یادگیری

Fig. 4: The error of Multi-Layer Perceptron (MLP) for different values of learning rate

نتایج و بحث

اعتبارسنجی بخار آب محصول مادون‌قرمز مودیس با استفاده از داده‌های رادیوسوند پیش از وارد شدن به مدل

جدول ۲ دقت کلی داده‌های بخار آب مادون‌قرمز مودیس در مقایسه با اندازه‌گیری‌های رادیوسوند با استفاده از معیارهای آماری را نشان می‌دهد. به‌طور کلی مقدار RMSE برابر ۴/۴۴ میلی‌متر، ضریب همبستگی ۰/۷۸ و مقدار بایاس ۰/۳۷- میلی‌متر به دست آمد. نتایج بدست‌آمده نشان می‌دهد که به‌طور متوسط، مقادیر بخار آب مودیس اندکی کمتر از اندازه‌گیری رادیوسوند برآورد شده‌اند. مقدار انحراف استاندارد تفاضل داده‌ها (STD) و میانگین داده‌های رادیوسوند (Mean) به‌ترتیب ۴/۴۲ و ۱۱/۷۴ میلی‌متر به دست آمد. شکل ۵ دیاگرام پراکنش داده‌های مودیس در برابر داده‌های رادیوسوند پیش از وارد شدن به مدل را نشان می‌دهد.

جدول ۲: خلاصه آمار مقایسه کلی داده‌های بخار آب محصولات مادون‌قرمز مودیس-آکوا و داده‌های بخار آب مشاهداتی از رادیوسوند

Table 2: Comparison of MODIS-Aqua IR Precipitable Water Vapor with Observed Data from 10 Local Radiosonde Stations

Time frame	Bias (mm)	RMSE (mm)	STD (mm)	R	Mean (mm)
2019-2020	-0.37	4.44	4.42	0.78	11.74

عملکرد مدل‌های شبکه عصبی MLP

در ابتدا مدل برآورد بخار آب قابل بارش (MODIS IR-Radiosonde PWV) با استفاده از الگوریتم پرسپترون چندلایه تشکیل گردید. برای

بررسی عملکرد مدل در گذرهای روز و شب ماهواره آکوا باتوجه به اینکه PWV استخراج به دست آمده از الگوریتم IR در زمان روز و شب می تواند دقت متفاوتی داشته باشند، لذا در این بخش به کمک روش شبکه عصبی پرسپترون چندلایه، دو مدل برآورد PWV یکی با استفاده ایستگاههایی که فقط در گذر روز ماهواره آکوا داده برداری می کنند و دیگری با استفاده ایستگاههایی که فقط در گذر شب ماهواره آکوا داده برداری می کنند، تشکیل گردید. از میان ۱۰ ایستگاه مطالعاتی رادیوسوند تعداد ۳ ایستگاه (اهواز-بیرجند-کرمان) فقط در روز، ۶ ایستگاه (اصفهان-شیراز-مشهد-زاهدان-کرمانشاه-تبریز) فقط در شب و یک ایستگاه (تهران) هم روز و هم شب داده برداری می نمایند. داده های ایستگاه تهران هم در ساخت مدل روز و هم مدل شب مورد استفاده قرار گرفتند. جدول ۴ نتایج مدل سازی PWV برای داده های شب و روز ماهواره آکوا با استفاده از شبکه عصبی MLP بر اساس پارامترهای آماری RMSE، bias، STD، R و مقایسه دقت مدل قبل و بعد از اعمال شبکه عصبی را نشان می دهد. شکل ۷ دیاگرام پراکنش داده های بخار آب استخراج شده از مدل شبکه عصبی پرسپترون چندلایه برای محصول مادون قرمز سنجندهی مودیس در مقایسه با داده های بخار آب برآورد شده ایستگاه های محلی رادیوسوند برای داده های روز و شب را نشان می دهد.


جدول ۴: نتایج به دست آمده از عملکرد مدل های شبکه عصبی MLP تشکیل شده

برای داده های روز و شب

Table 4: Results of MLP Neural Network Models for Daytime and Nighttime Data, including Correlation Coefficient (R), Standard Deviation (STD), RMSE, and Bias


	Bias (mm)	RMSE (mm)	STD (mm)	R
Night				
Original	0.28	4.84	4.83	0.77
MLP	0.01	3.08	3.10	0.83
Day				
Original	-1.22	3.83	3.63	0.83
MLP	-0.01	2.63	2.63	0.91

۰/۰۱ افزایش یافته که نشان می دهد مدل روی داده های جدید عملکردی تقریباً بدون خطای سیستماتیک دارد. به طور کلی بر اساس RMSE، دقت مدل در داده های آموزشی حدود ۳۶/۲۶٪ و در داده های اصلاح شده حدود ۳۴/۴۶٪ افزایش یافته است. بر اساس ضریب همبستگی، مدل در داده های آموزشی حدود ۱۲/۸۲٪ و در داده های اصلاح شده حدود ۱۱/۴۹٪ بهبود یافته است. این مقادیر نشان دهنده بهبود قابل توجه مدل پس از کالیبراسیون با شبکه عصبی MLP است، به ویژه در دقت داده های آموزشی و همچنین تعمیم پذیری آن در داده های اصلاح شده. شکل ۶ دیاگرام پراکنش داده های اصلاح شده بخار آب مودیس با استفاده از الگوریتم شبکه عصبی MLP در برابر داده های رادیوسوند را نشان می دهد.



شکل ۶: دیاگرام پراکنش داده های بخار آب اصلاح شده با استفاده از الگوریتم MLP در مقایسه با داده های بخار آب مشاهداتی رادیوسوند

Fig. 6: Scatter Plot of Calibrated MODIS Water Vapor Data Using MLP Versus Radiosonde Observations



شکل ۷: دیاگرام پراکنش داده های بخار آب استخراج شده از مدل شبکه عصبی MLP برای محصول مادون قرمز سنجندهی مودیس در مقایسه با داده های بخار آب برآورد رادیوسوند در: (الف) شب (ب) روز

Fig. 7: Scatter Plot of MODIS Water Vapor Data Extracted Using the MLP Model Versus Radiosonde Observations, including: (a) Nighttime (b) Daytime

تحلیل تفاوت دقت در نتایج مدل شب و روز

○ بر اساس نتایج ارائه شده، برای داده‌های شب، RMSE مدل پس از کالیبراسیون به ۳/۰۸ رسید و ضریب همبستگی ۰/۸۳ بود، و برای داده‌های روز، RMSE مدل پس از کالیبراسیون به ۲/۶۳ رسید و ضریب همبستگی ۰/۹۱ بود. این مقادیر نشان می‌دهند که مدل شبکه عصبی در پیش‌بینی داده‌های روز عملکرد بهتری دارد. دلایل احتمالی برای این تفاوت می‌تواند شامل موارد زیر باشد:

○ داده‌های روز غنی‌تر هستند و به شبکه عصبی اجازه می‌دهند الگوهای بیشتری را یاد بگیرد، زیرا کانال‌های مختلف در طول روز داده‌های بیشتری را ارائه می‌دهند.

○ پراکندگی کمتر و خطای سیستماتیک در داده‌های روز: به نظر می‌رسد داده‌های مودیس در روز کمتر تحت تأثیر خطاهای سیستماتیک باشند و شبکه عصبی بتواند با داده‌های ورودی دقیق‌تر، مدل بهتری را آموزش دهد.

نتیجه‌گیری

این مطالعه با هدف ارزیابی دقت داده‌های بخار آب قابل بارش (PWV) حاصل از سنجنده مادون قرمز مودیس (MYD05) ماهواره آکوا، با استفاده از داده‌های رادیوسوند در ده ایستگاه محلی ایران طی سال‌های ۲۰۱۹-۲۰۲۰ انجام شد. پس از پیش‌پردازش داده‌ها و حذف مقادیر نامعتبر و پرت، نتایج نشان داد که همبستگی متوسطی ($R=0.78$) بین داده‌های مودیس و رادیوسوند وجود دارد، در حالی که RMSE برابر ۴/۴۴ میلی‌متر و بایاس اندکی منفی (۰/۳۷- میلی‌متر) مشاهده شد. با این حال، به کارگیری مدل شبکه عصبی پرسپترون چندلایه (MLP) باعث بهبود چشمگیر دقت برآورد PWV شد و خطای RMSE را به ۲/۸۳ میلی‌متر در داده‌های آموزشی و ۲/۹۱ میلی‌متر در مرحله اعتبارسنجی کاهش داد. همچنین، ضریب همبستگی به ترتیب به ۰/۸۸ و ۰/۸۷ افزایش یافت. عملکرد مدل در داده‌های روز ($RMSE=2.63$ mm) بهتر از داده‌های شب ($RMSE=3.08$ mm) بود که احتمالاً ناشی از اطلاعات غنی‌تر روز و خطاهای کمتر سیستماتیک است. در نهایت، این پژوهش نشان داد که استفاده از مدل MLP می‌تواند دقت داده‌های PWV مودیس را به طور قابل توجهی افزایش داده و بایاس سیستماتیک را کاهش دهد. این امر موجب ارتقای قابلیت اطمینان داده‌های ماهواره‌ای در مطالعات جوی و کاربردهای عملی مرتبط خواهد شد.

مشارکت نویسندگان

اسلام جوادنیا در ایده‌پردازی، طراحی پژوهش، جمع‌آوری و تحلیل داده‌ها و نگارش پیش‌نویس مقاله نقش داشته است. کمال قبادی در جمع‌آوری و تحلیل داده‌ها و اصلاح اساسی دست‌نوشته مشارکت کرده است. هادی جلیلی و آرش زندکریمی در ایده‌پردازی و اصلاح اساسی نسخه نهایی سهمیه بوده‌اند.

نتایج مدل‌سازی برای داده‌های شب به شرح زیر است:

نتایج ارزیابی داده‌های اصلی (قبل از کالیبراسیون) نشان می‌دهد که انحراف معیار، RMSE، بایاس و ضریب همبستگی به ترتیب برابر با ۴/۸۳، ۴/۸۴، ۰/۲۸ میلی‌متر و ۰/۷۷ است. این مقادیر نشان‌دهنده دقت داده‌های اصلی بخار آب در زمان شب بدون استفاده از مدل شبکه عصبی هستند. ضریب همبستگی برابر با ۰/۷۷ نشان می‌دهد که رابطه نسبی خوبی بین داده‌های اصلی و داده‌های واقعی وجود دارد، اما همچنان جا برای بهبود وجود دارد. پس از استفاده از مدل شبکه عصبی MLP برای داده‌های شب، نتایج نشان می‌دهد که انحراف معیار، RMSE، بایاس و ضریب همبستگی (R) به ترتیب به ۳/۰۸، ۳/۰۸، ۰/۰۱ میلی‌متر و ۰/۸۳ بهبود یافته است. این نتایج نشان‌دهنده افزایش دقت مدل پس از کالیبراسیون است. به‌طور کلی، مقدار RMSE از ۴/۸۴ به ۳/۰۸ کاهش یافته است، که معادل بهبود ۳۶/۴۰ درصدی در دقت پیش‌بینی است. همچنین، مقدار بایاس مدل از ۰/۲۸ به ۰/۰۱ کاهش یافته است که نشان‌دهنده حذف تقریباً کامل خطای سیستماتیک در پیش‌بینی داده‌های شب است. انحراف معیار نیز از ۴/۸۳ به ۳/۰۸ کاهش یافته است، و ضریب همبستگی از ۰/۷۷ به ۰/۸۳ افزایش یافته است. این نتایج به‌طور کلی نشان می‌دهند که استفاده از مدل شبکه عصبی MLP باعث بهبود قابل توجه دقت پیش‌بینی بخار آب قابل بارش در داده‌های شب شده است.

نتایج مدل‌سازی برای داده‌های روز به شرح زیر است:

نتایج ارزیابی داده‌های اصلی (قبل از کالیبراسیون) نشان می‌دهد که انحراف معیار، RMSE، بایاس و ضریب همبستگی به ترتیب برابر با ۳/۶۳، ۳/۸۳، ۱/۲۲- میلی‌متر و ۰/۸۳ است. این مقادیر نشان‌دهنده دقت داده‌های اصلی بخار آب در زمان روز بدون استفاده از مدل شبکه عصبی هستند. مقدار بایاس منفی (۱/۲۲-) نشان‌دهنده وجود خطای سیستماتیک در داده‌های اصلی است. پس از استفاده از مدل شبکه عصبی MLP برای داده‌های روز، نتایج نشان می‌دهد که انحراف معیار، RMSE، بایاس و ضریب همبستگی به ترتیب به ۲/۶۳، ۲/۶۳، ۰/۰۱- میلی‌متر و ۰/۹۱ بهبود یافته است. این نتایج نشان‌دهنده افزایش دقت مدل پس از کالیبراسیون است. به‌طور کلی، مقدار RMSE از ۳/۸۳ به ۲/۶۳ کاهش یافته است، که معادل بهبود ۳۱/۴۶ درصدی در دقت پیش‌بینی است. همچنین، مقدار بایاس مدل از ۱/۲۲- به ۰/۰۱- کاهش یافته است که نشان‌دهنده حذف تقریباً کامل خطای سیستماتیک در پیش‌بینی داده‌های روز است. انحراف معیار نیز از ۳/۶۳ به ۲/۶۳ کاهش یافته است، و ضریب همبستگی از ۰/۸۳ به ۰/۹۱ افزایش یافته است. این نتایج به‌طور کلی نشان می‌دهند که استفاده از مدل شبکه عصبی MLP باعث بهبود قابل توجه دقت پیش‌بینی بخار آب قابل بارش در داده‌های روز شده است و خطاهای سیستماتیک موجود در داده‌های اصلی را کاهش داده است.

[11] Norouzi Razieh, J.E., Validation of precipitable water vapor derived from MODIS infrared product using GPS observations, in The Second National Conference on Data Mining in Earth Sciences. 2021: Arak, Iran.

[12] Lindenbergh, R., et al. Validating time series of a combined GPS and MERIS Integrated Water Vapor product. in Proceedings 2nd MERIS/(A) ATSR User Workshop. 2008.

[13] Li, Z. Production of Regional 1 km×1 km Water Vapor Fields through the Integration of GPS and MODIS Data. in Proceedings of the 17th International Technical Meeting of the Satellite Division of The Institute of Navigation (ION GNSS 2004). 2004.

[14] Zhang, B., et al., Precipitable water vapor fusion: an approach based on spherical cap harmonic analysis and Helmert variance component estimation. *Journal of Geodesy*, 2019. 93(12): p. 2605-2620. DOI: 10.1007/s00190-019-01322-0

[15] Zhao, Q., et al., Precipitable water vapor fusion method based on artificial neural network. *Advances in Space Research*, 2022. 70(1): p. 85-95. DOI: 10.1016/j.asr.2022.04.016

[16] Zhang, B. and Y. Yao, Precipitable water vapor fusion based on a generalized regression neural network. *Journal of geodesy*, 2021. 95(3): p. 36. DOI: 10.1007/s00190-021-01482-3

[17] Xu, J. and Z. Liu, Enhanced all-weather precipitable water vapor retrieval from MODIS near-infrared bands using machine learning. *International Journal of Applied Earth Observation and Geoinformation*, 2022. 114: p. 103050. DOI: 10.1016/j.jag.2022.103050

[18] Ghaderi, M. and M. Rahimzadegan, Improving precipitable water vapor estimations of the Moderate Resolution Imaging Spectroradiometer (MODIS) using metaheuristic algorithms. *Advances in Space Research*, 2022. DOI: 10.1016/j.asr.2022.06.046

[19] Xiong, Z., et al., Modify the accuracy of MODIS PWV in China: A performance comparison using random forest, generalized regression neural network and back-propagation neural network. *Remote Sensing*, 2021. 13(11): p. 2215. DOI: 10.3390/rs13112215

[20] Xu, J., et al., A New Machine Learning Based Calibration Scheme for MODIS Thermal Infrared Water Vapor Product Using BPNN, GBDT, GRNN, KNN, MLPNN, RF, and XGBoost. *IEEE Transactions on Geoscience and Remote Sensing*, 2024. DOI: 10.1109/TGRS.2024.3350476

[21] Lee, Y., et al., Retrieval of total precipitable water from Himawari-8 AHI data: A comparison of random forest, extreme gradient boosting, and deep neural network. *Remote Sensing*, 2019. 11(15): p. 1741. DOI: 10.3390/rs11151741

[22] Amiri, M.J. and S. Eslamian, Investigation of Climate Change in Iran. *Journal of Environmental Science and Technology*, 2010. 3. <https://doi.org/10.3923/jest.2010.208.216>

تشکر و قدردانی

بدین‌وسیله از کلیه عزیزانی که ما را در انجام این تحقیق یاری کردند، صمیمانه تشکر می‌کنیم.

تعارض منافع

«هیچ‌گونه تعارض منافع توسط نویسندگان بیان نشده است.»

منابع و مآخذ

[1] Bevis, M., et al., GPS meteorology: Remote sensing of atmospheric water vapor using the global positioning system. *Journal of Geophysical Research: Atmospheres*, 1992. 97(D14): p. 15787-15801. DOI: 10.1029/92JD01517

[2] Mockler, S., Water vapor in the climate system, special report, American Geophysical Union (AGU), 2000 Florida Ave., NW, Washington, DC 20009. 1995, December.

[3] Gao, B.-C., et al., Measurements of water vapor and high clouds over the Tibetan Plateau with the Terra MODIS instrument. *IEEE Transactions on geoscience and remote sensing*, 2003. 41(4): p. 895-900. DOI: 10.1109/TGRS.2003.810704

[4] Held, I.M. and B.J. Soden, Water vapor feedback and global warming. *Annual review of energy and the environment*, 2000. 25(1): p. 441-475. DOI: 10.1146/annurev.energy.25.1.441

[5] urre, I., R.S. Vose, and D.B. Wuertz, Overview of the integrated global radiosonde archive. *Journal of Climate*, 2006. 19(1): p. 53-68. DOI: 10.1175/JCLI3594.1

[6] Vaquero-Martínez, J. and M. Antón, Review on the role of GNSS meteorology in monitoring water vapor for atmospheric physics. *Remote Sensing*, 2021. 13(12): p. 2287. DOI: 10.3390/rs13122287

[7] Gao, B.-C. and Y.J. Kaufman, The MODIS near-IR water vapor algorithm. *Algorithm Theoretical Basis Document, ATBD-MOD*, 1998. 5.

[8] Van Malderen, R., et al., A multi-site intercomparison of integrated water vapour observations for climate change analysis. *Atmospheric Measurement Techniques*, 2014. 7(8): p. 2487-2512. DOI: 10.5194/amt-7-2487-2014

[9] Javadnia, E., N. Beygi, and S. Abbasy, Comparison and Evaluation of MODIS and Sun photometer Integrated water vapor using GPS observations at IASBS AERONET site (Zanjan, Iran). *Journal of Geomatics Science and Technology*, 2021. 11(1): p. 117-128. <https://dor.isc.ac/dor/20.1001.1.2322102.1400.11.1.9.7>

[10] Liu, H., et al., Evaluation of MODIS water vapour products over China using radiosonde data. *International Journal of Remote Sensing*, 2015. 36(2): p. 680-690. DOI: 10.1080/01431161.2014.999880

review. International journal of remote sensing, 2018. 39(9): p. 2784-2817. DOI: 10.1080/01431161.2018.1433343

[35] Scornet, E., G. Biau, and J.-P. Vert, Consistency of random forests. 2015. DOI: 10.1214/15-AOS1321

[36] Charu C, A., Neural networks and deep learning: a textbook. 2018: Springer. DOI: 10.1214/15-AOS1321

[37] Nair, V. and G.E. Hinton. Rectified linear units improve restricted boltzmann machines. in Proceedings of the 27th international conference on machine learning (ICML-10). 2010. June 21-24, Haifa, Israel

[38] Weisstein, E.W., Hyperbolic Functions., 2003.

[39] Chauvin, Y. and D.E. Rumelhart, Backpropagation: theory, architectures, and applications. 2013: Psychology press. <https://doi.org/10.4324/9780203763247>

[40] Kingma, D.P., Adam: A method for stochastic optimization. arXiv preprint arXiv:1412.6980, 2014. <https://doi.org/10.48550/arXiv.1412.6980>

[41] Hastie, T., The elements of statistical learning: data mining, inference, and prediction. 2009, Springer. <https://doi.org/10.1007/978-0-387-84858-7>

[23] asakereh, H. and m. dostkamian, Survey of role of spatial factors on distribution- dispersion of maximums perceptible water in atmosphere of Iran. Journal of Applied Research in Geographical Sciences, 2015. 15(36): p. 7-24. <http://dori.net/dor/20.1001.1.22287736.1394.15.36.2.8>

[24] Seemann, S.W., et al., Operational retrieval of atmospheric temperature, moisture, and ozone from MODIS infrared radiances. Journal of applied meteorology, 2003. 42(8): p. 1072-1091. DOI: 10.1175/1520-0450(2003)042<1072:OROATM>2.0.CO;2

[25] Borbas, E. and P. Menzel, MODIS Atmosphere L2 Atmosphere Profile Product, NASA MODIS Adaptive Processing System, Goddard Space Flight Center [data set], USA. 2015, August. http://dx.doi.org/10.5067/MODIS/MOD07_L2.006

[26] Niell, A., et al., Comparison of measurements of atmospheric wet delay by radiosonde, water vapor radiometer, GPS, and VLBI. Journal of Atmospheric and Oceanic Technology, 2001. 18(6): p. 830-850. DOI: 10.1175/1520-0426(2001)018<0830:COMOAW>2.0.CO;2

[27] Bolton, D., The computation of equivalent potential temperature. Monthly weather review, 1980. 108(7): p. 1046-1053. DOI: 10.1175/1520-0493(1980)108<1046:TCOEPT>2.0.CO;2

[28] Wang, J. and L. Zhang, Systematic errors in global radiosonde precipitable water data from comparisons with ground-based GPS measurements. Journal of Climate, 2008. 21(10): p. 2218-2238. DOI: 10.1175/2007JCLI1944.1. DOI: 10.1016/j.atmosres.2017.07.021

[29] Gui, K., et al., Evaluation of radiosonde, MODIS-NIR-Clear, and AERONET precipitable water vapor using IGS ground-based GPS measurements over China. Atmospheric Research, 2017. 197: p. 461-473. DOI: 10.1016/j.atmosres.2017.07.021

[30] Wang, H., et al., Prediction models of soil heavy metal (loid) s concentration for agricultural land in Dongli: A comparison of regression and random forest. Ecological Indicators, 2020. 119: p. 106801. DOI: 10.1016/j.ecolind.2020.106801

[31] Vapnik, V. and A. Vashist, A new learning paradigm: Learning using privileged information. Neural networks, 2009. 22(5-6): p. 544-557. DOI: 10.1016/j.neunet.2009.06.042

[32] Larya, D.J., et al., Machine learning in geosciences and remote sensing. Geoscience Frontiers, 2015. 30: p. 1e9. DOI: 10.1016/j.gsf.2015.07.003

[33] Li, J. and A.D. Heap, A review of comparative studies of spatial interpolation methods in environmental sciences: Performance and impact factors. Ecological Informatics, 2011. 6(3-4): p. 228-241. DOI: 10.1016/j.ecoinf.2010.12.003

[34] Maxwell, A.E., T.A. Warner, and F. Fang, Implementation of machine-learning classification in remote sensing: An applied

معرفی نویسندگان

AUTHOR(S) BIOSKETCHES



کمال قبادی دارای تحصیلات کارشناسی در رشته مهندسی عمران - نقشه‌برداری و کارشناسی ارشد ژئودزی از دانشگاه زنجان است. وی از سال ۱۴۰۲ تاکنون به‌عنوان دانشجوی دکتری ژئودزی در دانشگاه تهران مشغول به تحصیل و در زمینه ی یادگیری ماشین و هوش مصنوعی در این حوزه مشغول به کار است.

Ghobadi, K. Department of Geomatics Engineering, Faculty of Engineering, University of Zanjan, Zanjan, Iran

✉ Kghobadi741@gmail.com



اسلام جوادنیا استادیار گروه مهندسی نقشه‌برداری در دانشکده مهندسی دانشگاه زنجان است. ایشان مدرک کارشناسی ارشد و دکتری خود را در رشته مهندسی نقشه‌برداری - سنجش از دور به‌ترتیب در سال‌های ۱۳۸۶ و ۱۳۹۶ از دانشگاه صنعتی خواجه نصیرالدین طوسی دریافت کرده‌اند.

فعالیت‌های پژوهشی اخیر ایشان در زمینه کاربرد یادگیری ماشین در برآورد پارامترهای جوی و همچنین به‌کارگیری سنجش از دور در پایش تغییرات اقلیمی، کشاورزی، مدیریت جنگل‌ها، مدیریت کاربری و پوشش اراضی و مدل‌سازی محیطی با استفاده از داده‌های سنجش از

Jalili, H. Assistant Professor, Iranian Space Research Center, Tehran, Iran

✉ h.jalili@isrc.ac.ir



آرش زندکریمی مدرک کارشناسی ارشد خود را در رشته GIS و سنجش از دور از دانشگاه تبریز در سال ۱۳۹۴ دریافت کرده و در حال حاضر دانشجوی دکتری سنجش از دور در دانشگاه تربیت مدرس و پژوهشگر پژوهشگاه فضایی ایران است. فعالیت‌های پژوهشی وی بر

پایش ماهواره‌ای زمین در حوزه‌های مختلفی از جمله کاربری اراضی، نقشه‌برداری محصولات کشاورزی (Crop Mapping)، پایش گردوغبار، پتانسیل‌یابی و سایر کاربردهای مرتبط متمرکز است. زمینه‌های تخصصی او شامل پردازش تصاویر ماهواره‌ای، یادگیری ماشین، توسعه کاربردهای سنجش از دور و هوش مصنوعی در مدیریت زمین می‌باشد.

Zandkarimi, A. Ph.D. Candidate in Remote Sensing, Researcher at the Iranian Space Research Center, Iran

✉ Zandkarimi.arash@gmail.com

دور متمرکز است. زمینه‌های تخصصی وی عبارت‌اند از پردازش تصاویر اپتیکی و راداری، یادگیری ماشین و توسعه کاربردهای سنجش از دور.

Javadnia, E. Assistant Professor at the Department of Geomatics Engineering, Faculty of Engineering, University of Zanjan, Zanjan, Iran

✉ Javadnia@znu.ac.ir



هادی جلیلی استادیار پژوهشگاه فضایی ایران

است. وی مدرک کارشناسی ارشد و دکتری خود را در رشته مهندسی مکانیک از دانشگاه صنعتی شریف دریافت کرده است. فعالیت‌های پژوهشی وی در حوزه‌های مختلف از جمله پایش ماهواره‌ای زمین، کالیبراسیون تصاویر ماهواره‌ای،

مدل‌سازی، تحلیل ربات‌های میکرونی ارتعاشی و طراحی و کنترل سازه‌های انعطاف‌پذیر در سامانه‌های فضایی متمرکز است. زمینه‌های تخصصی او شامل کنترل ارتعاشات، پردازش تصاویر ماهواره‌ای، هوش مصنوعی، مدل‌سازی، شبیه‌سازی سازه‌های پیزوالکتریک و طراحی ربات‌های میکرونی با عملگرهای پیزوالکتریک می‌باشد.

Citation (Vancouver): Ghobadi K, Javadnia E, Jalili H, Zandkarimi A. [Calibration of MODIS Water vapor data using multi-Layer perceptron neural network and radiosonde observations]. *J. RS. GEOINF. RES.* 2025; 3(1): 1-14

doi <https://doi.org/10.22061/jrsgr.2025.11605.1090>



COPYRIGHTS

© 2025 The Author(s). This is an open-access article distributed under the terms and conditions of the Creative Attribution-NonCommercial 4.0 International (CC BY-NC 4.0) (<https://creativecommons.org/licenses/by-nc/4.0/>)