

## ارزیابی و پیش بینی آب و هوا با هدف بارش باران طی فصل های یک سال در شهر تهران با رویکرد مدل طیفی خطی

عبدالرحمان ابراهیمی<sup>\*۱</sup>

کارشناسی ارشد آب و هواشناسی گرایش آب و هواشناسی کاربردی

Novin.4058@yahoo.com

### چکیده

آب و هوا به عنوان یک مولفه مهم در جوامع امروزی برای زیستن شناخته می شود. عوامل متعددی بر ساختار زندگی انسان ها و موجودات تاثیرگذارند که مهمترین گزینه، آب و هوا است. آب و هوا نیاز به سیستم هایی دارد که به صورت هوشمند، قابلیت اندازه گیری، ارزیابی و ارائه پیش بینی هایی برای آینده را داشته باشد. البته هدف از پیش بینی آب و هوا، می تواند اهداف گوناگونی مانند بارش باران، برف، تگرگ، طوفان و غیره باشد. این تحقیق سعی در استفاده از یک سیستم آشوب ناک برای در نظر گرفتن احتمالات در پیش بینی آب و هوا با هدف تخمین بارش باران را مدنظر قرار می دهد. رویکرد پیشنهادی بدین صورت است که بر اساس ساختار سیستم های پیچیده و تئوری کنترل پذیری، یک چارچوب ارائه می گردد تا جهت پیش بینی باران، نگاشت هایی در زمان های مختلف ثبت شده در داده، لحاظ شود. این عملیات با استفاده از مدل طیفی خطی صورت می پذیرد. در نهایت بر اساس یک سیستم تصمیم گیری، بهینه سازی کلاس های پیش بینی انجام و نمایش و تخمین مقدار آب، انجام می گیرد که مبتنی بر درخت های تصمیم خواهد بود. از مجموعه داده های بزرگ آب و هوا در شهر تهران برای سال ۱۳۹۶ برای این کار استفاده شده است.

کلمات کلیدی: پیش بینی آب و هوا، پیش بینی بارش باران، سیستم های آشوب ناک، مدل طیفی خطی، درخت تصمیم

### ۱- مقدمه

به طور واضح و مبرهن می توان گفت که کشاورزی، ستون فقرات هر کشوری در دنیا محسوب می شود. بهبود تسهیلات آبیاری در زمین های کشاورزی می تواند منجر به افزایش برداشت محصول در زمان مقرر می شود و همچنین بهینه سازی مصرف آب را نیز در پی خواهد داشت. از آن جا که آبیاری نیاز به آب باران دارد، می بایست در منطقه کشاورزی، بارانی وجود داشته باشد که بتوان این مسئله را مرتفع ساخت. همچنین اگر در آن منطقه، بارش بارانی وجود ندارد، می بایست آب را از طریق لوله کشی به سمت زمین های کشاورزی از مناطق دیگر، هدایت نمود. نتیجه یک بارش باران مناسب با وقوع دوره رطوبت برای مدت زیادی، می تواند بارش باران را به ارمغان آورد که تاثیر شگرفی در کشاورزی و در ابعاد وسیع تر برای اقتصاد یک کشور، به همراه دارد. داشتن دانش در رابطه با باران های فصلی، می تواند به برنامه ریزی کشاورزان کمک شایانی نماید. ویژگی ها و مقدار بارش باران، امری هستند که به سادگی قابل اندازه گیری نمی باشند. باران یک نقش اساسی و حیاتی در ارزیابی و مدیریت پیشامدهای خشکی و سیل را ایفا می کند. با همه این تفاسیر و مواردی دیگری که در حوصله این بحث نمی گنجد، پیش بینی دمای آب و هوا دارای اهمیت فراوانی است. مسلما میزان بارش باران، بر اساس پیش بینی دمای آب و هوا می باشد. لذا شناسایی مقدمات بارش باران، امری ضروری است [۱].

تا به امروز، بازه وسیعی از روش های پیش بینی بارش باران در پیش بینی هواشناسی در ابعاد منطقه ای و استانی، به کار گرفته شده است. به صورت کلی، دو رویکرد جهت پیش بینی بارش باران وجود دارد که شامل رویکرد تجربی و پویا است. رویکرد تجربی برپایه تحلیل داده های قدیمی گذشته از شرایط هوایی است و وابسته به تنوع متغیرهای اتمسفری در مناطق مختلف می باشد. گسترده ترین استفاده از رویکردهای تجربی برای پیش بینی اقلیمی با استفاده از رگرسیون<sup>۱</sup>، منطق فازی<sup>۲</sup>، شبکه های عصبی مصنوعی<sup>۳</sup> و روش های گروهی از داده های در دسترس<sup>۴</sup> مورد استفاده واقع می شوند. پیش بینی مبتنی بر رویکرد پویا توسط مدل های فیزیکی در سیستم معادلاتی که عملیات پیش بینی بارش باران آینده را انجام می دهند، ایجاد می شود. پیش بینی هوا توسط کامپیوتر با استفاده از معادلات به عنوان پیش بینی هوا به صورت عددی، شناخته شده است. هواشناسان به منظور پیش بینی هوا با استفاده از اعداد، به ایجاد مدل های اتمسفری که عملیات تخمین تغییرات در حرارت، فشار و غیره را برپایه معادلات ریاضی انجام می دهند، پرداخته اند [۳، ۲].

ارائه راهکارهای هوشمند در پیش بینی آب و هوا با هدف مشخص نمودن میزان و زمان بارش باران، یک غالب پیچیده دارد که به نام سیستم های پیچیده نام گذاری می شود. سیستم های پیچیده<sup>۵</sup> نگاهی نو به پدیده های است که به علت ارتباط بین اجزای آن و همچنین ارتباط با دیگر پدیده ها، از پیچیدگی بالایی برخوردار هستند و رفتار جمعی متفاوتی بروز می دهند. بدین معنی که با مطالعه تک تک اجزای یک سیستم پیچیده نمی توان به رفتار جمعی آن دست یافت. به عبارت دیگر، سیستم پیچیده معرف پارادایم پیچیدگی است که عناصر سازنده آن تشکیل سیستمی را می دهند که اجزای سیستم دارای برهم کنش هستند و از اندیشه کل نگر، بهره می گیرند. پارادایم کلاسیک که بخشی نگر است، بر این فرض استوار است که اگر اجزای سیستمی را دقیقاً شناسایی کند و از عملکرد آن اطلاع کسب نماید، قادر خواهد بود به خواص کلی پدیده و سیستم دست یابد. مطالعات کیهان شناسی، ساختارهای بی نظم در مواد، زیست شناسی، جامعه شناسی و اقتصاد، محدودیت کاربرد این مسئله را در مقالات و کتاب های متعدد به نمایش گذاشته اند. به منظور کنترل سیستم های پیچیده با ماهیت غیرخطی در دنیای واقعی، استفاده از فرایندهای پویای غیرخطی در دنیای شبیه سازی نیز امری مفید به نظر می رسد. اما استفاده از روش های خطی نیز در آن سوی ماجرا نیز دارای اهمیت فراوانی است. یکی از این روش ها، مدل طیفی خطی است که برای هوشمند سازی آن، از ساختار درخت تصمیم<sup>۶</sup> بهره گرفته شده است. این پژوهش، سعی در پیش بینی آب و هوا با هدف بارش باران در یک سال در شهر تهران بر اساس داده های موجود اما به صورت پویا را دارد. بدین منظور، استفاده از ساختار سیستم های پیچیده و تئوری کنترل پذیری مدنظر می باشد که به عنوان یک چارچوب ارائه می گردد و به منظور پیش بینی آب و هوا با هدف بارش باران، از نگاشت های آشوب ناک یعنی مدل طیفی خطی استفاده خواهد شد. در نهایت درخت تصمیم دودویی، بهینه سازی کلاس های پیش بینی را با درخت تصمیم دودویی، نمایش و تخمین مقدار آب را انجام می دهد.

## ۲- ادبیات تحقی

در این بخش، نیاز است تا یک سری واژه های فنی و تخصصی، توضیحی مختصر داده شوند تا در ادامه، بتوان مطالعه ای دقیق بر روی حوزه این تحقیق، ارائه نمود.

✓ سیستم های پیچیده: سیستم پیچیده معرف پارادایم پیچیدگی است که عناصر سازنده آن تشکیل سیستمی را می دهند که اجزای سیستم دارای برهم کنش هستند و از اندیشه کل نگر، بهره می گیرند. پارادایم کلاسیک که بخشی نگر است، بر این فرض استوار است که اگر اجزای سیستمی را دقیقاً شناسایی کند و از عملکرد آن اطلاع کسب نماید، قادر خواهد بود به خواص کلی پدیده و سیستم دست یابد.

<sup>1</sup> Regression

<sup>2</sup> Fuzzy Logic

<sup>3</sup> Artificial Neural Networks (ANN)

<sup>4</sup> Group Method of Data Handling (GMDH)

<sup>5</sup> Complex Systems

<sup>6</sup> Decision Tree

## سومین همایش ملی مهندسی کامپیوتر، داده کاوی و داده های حجیم

- ✓ یادگیری ماشین: یادگیری ماشین به عنوان یکی از شاخه های وسیع و پرکاربرد هوش مصنوعی، به تنظیم و اکتشاف شیوه ها و الگوریتم هایی می پردازد که بر اساس آن ها رایانه ها و سامانه ها توانایی یادگیری پیدا می کنند؛ یعنی برنامه های کامپیوتری می توانند با گذشت زمان، عملکرد خود را بر اساس داده های دریافتی بهبود بخشند.
- ✓ نظریه آشوب: مطالعه سیستم های دینامیکی آشوب ناک که غیرخطی می باشند و به شدت حساس به شرایط اولیه هستند. تغییر اندک در شرایط اولیه منجر به تغییرات فراوان در آینده می گردد که از این رو در عملیات پیش بینی یک فرایند بسیار مناسب به نظر می رسند.
- ✓ درخت تصمیم دودویی: تکنیک یادگیری ماشین برای استنتاج یک درخت تصمیم از داده ها، یادگیری درخت تصمیم نامیده می شود که یکی از رایج ترین روش های داده کاوی است. ساختار درخت تصمیم در یادگیری ماشین، یک مدل پیش بینی کننده می باشد که حقایق مشاهده شده در مورد یک پدیده را به استنتاج هایی در مورد مقدار هدف آن پدیده نقش می کند. درختان تصمیم قادر به تولید توصیف های قابل درک برای انسان، از روابط موجود در یک مجموعه داده ای هستند و می توانند برای وظایف دسته بندی و پیش بینی به کار روند.

### ۳- مروری بر پیشینه تحقیق

یکی از مهمترین تحقیقاتی که در زمینه پیش بینی آب و هوا مبتنی بر اینترنت اشیا ارائه شده است و به عنوان مقاله اصلی و مرجع این تحقیق نیز به شمار می رود، مرجع [۴] است. استفاه از یک سری ماژول شامل Xbee Wi-Fi و کنترل کننده آردینو<sup>۱</sup> به عنوان حسگر دریافت کننده اطلاعات وابسته و متصل به اینترنت اشیا مدنظر قرار گرفته است. بر اساس اطلاعاتی که در پایگاه داده به کمک رسپیری<sup>۲</sup> قرار می گیرد، اطلاعات به گوشی همراه برای تحلیل ارسال می شود. در بخش تحلیل نیز از روش ترکیبی رگرسیون خطی به همراه نزدیک ترین همسایه K<sup>۳</sup> استفاده شده است. نرخ میانگین خطای کمتر نسبت به روش های تحلیلی دیگر، نشان از بهبود رویکرد پیشنهادی را نشان می دهد. در یک تحقیق دیگر بدون استفاده از حسگرها، عملیات پیش بینی آب و هوا انجام گرفته است [۵]. استفاده از یک مدل شبکه های هیدروکربن مصنوعی<sup>۴</sup> برای پیش بینی آب و هوا مدنظر قرار گرفته شده است. استفاده از خدمات وب بر اساس اطلاعات دریافتی از اینترنت اشیا و تحلیل بالادرنگ با روش نام برده، به عنوان بخش اصلی این تحقیق، می باشد.

تا به امروز روش های متنوعی برای پیش بینی درجه هوا بر اساس معیارهایی هم چون بارش باران باران ارائه شده است. از جمله مهمترین پژوهش هایی که در زمینه پیش بینی آب و هوا انجام گرفته است که در نهایت به پردازش بعدی یعنی پیش بینی بارش باران منجر شده است، می توان به [۶-۷] اشاره نمود. در [۶] روش درخت تصمیم برای پیش بینی بارش باران و تغییرات اقلیمی مورد بررسی واقع شده است. در [۷] استفاده از شبکه عصبی پس انتشار خطا<sup>۵</sup> برای آموزش داده ها و استفاده از الگوریتم ژنتیک<sup>۶</sup> جهت بهینه سازی پارامترها و کلاس ها با هدف پیش بینی بارش باران ارائه شده است. در [۸، ۹] از منطق فازی با توابع عضویت<sup>۷</sup> و قوانین فازی<sup>۸</sup> برای پیش بینی بارش باران استفاده شده است.

شبکه های عصبی دارای اهمیت بالایی در پیش بینی بارش باران بوده اند که تا به امروز روش های فاونی برپایه آن ارائه و تدوین شده است. در [۱۰] از شبکه عصبی چندلایه پس انتشار خطا با در نظر گرفتن پارامترهای بارش باران چون سرعت

<sup>1</sup> Arduino Controller

<sup>2</sup> Raspberry

<sup>3</sup> K-Nearest Neighbor (KNN)

<sup>4</sup> Artificial hydrocarbon networks model

<sup>5</sup> Back-Propagation Error Neural Network (BP NN)

<sup>6</sup> Genetic Algorithm (GA)

<sup>7</sup> Membership Functions (MFs)

<sup>8</sup> Fuzzy Rules

## سومین همایش ملی مهندسی کامپیوتر، داده کاوی و داده های حجیم

باد، میانگین درجه حرارت، رطوبت و مقدار آئروسول<sup>۱</sup> جهت پیش بینی استفاده شده است که برای مجموعه داده های سال ۱۹۷۸ میلادی بوده است. در پژوهشی دیگر، از شبکه عصبی پیش خور<sup>۲</sup> برای پیش بینی بارش باران در بین سال های ۲۰۰۸ الی ۲۰۱۵ با توجه به داده های ۵۰ ساله از ۱۹۵۱ الی ۲۰۰۷ استفاده شده است که با در نظر گرفتن رطوبت، مقدار شبنم و فشار هوا، به عنوان پارامترهای پیش بینی، عملیات صورت گرفته است [۱۱].

به عنوان توسعه پژوهش [۱۱] شبکه عصبی چندلایه پیش خور<sup>۳</sup> ارائه شده است که به تخمین و پیش بینی بارش باران برای سال های بعد از ۲۰۱۰ میلادی می پردازد. مجموعه داده های آموزش برای سال های ۱۸۷۱ الی ۲۰۱۰ است که در کل ۱۴۰ سال مجموعه داده در این پژوهش کاربردی مورد استفاده واقع شده است. حداکثر و حداقل حرارت به عنوان پارامترهای پیش بینی، مورد استفاده واقع شده اند [۱۲]. مشابه با پژوهش [۱۱] از شبکه عصبی پیش خور با در نظر گرفتن پارامترهایی چون سرعت باد، درجه حرارت و رطوبت، به پیش بینی ۲۰٪ از کل ۸۰٪ داده های یک ماه از بارش باران، پرداخته شده است [۱۳].

استفاده از دو شبکه عصبی خاص به نام های شبکه عصبی میانگین متحرک<sup>۴</sup> و شبکه عصبی طیف منفرد<sup>۵</sup> با در نظر گرفتن پارامترهای پیش بینی حداقل و حداکثر حرارت در پیش بینی بارش باران مورد استفاده واقع شده است [۱۴]. در یک پژوهش دیگر به ترکیب شبکه عصبی مصنوعی با تبدیل موجک<sup>۶</sup> پرداخته شده است که با در نظر گرفتن پارامترهای پیش بینی همچون حداقل و حداکثر حرارت، مقدار تبخیر، رطوبت، باران در روز اول و روز دوم و میانگین آن، به پیش بینی بارش باران برای سال های ۲۰۰۱ الی ۲۰۰۲ با ورودی های ۱۹۹۱ الی ۲۰۰۰ یعنی داده ۹ ساله، انجام گرفته است [۱۵]. استفاده از یک رویکرد ترکیبی فازی-عصبی نیز مدنظر بوده است که در [۱۶] ارائه شده است. همچنین این روش ترکیبی فازی-عصبی با استفاده از جعبه ابزار انفیس<sup>۷</sup> نیز مورد بررسی واقع شده است [۱۷].

در [۱۸] پیش بینی بارش باران با رویکرد داده کاوی و تحلیل های آماری با قوانین انجمنی<sup>۸</sup> انجام گرفته است که در مرحله بعدی، عملیات خوشه بندی به منظور کاهش ابعاد صورت می پذیرد که این عملیات مبتنی بر طبقه بندی منطق فازی است. در یک روش ترکیبی دیگر به ترکیب شبکه عصبی پرسپترون چندلایه با موجک چندلایه جهت پیش بینی بارش باران پرداخته شده است که پیش بینی زودهنگام، از مزایای این روش تلقی می گردد که توانایی پیش بینی برای ۵ روز آینده را دارا می باشد [۱۹]. یک روش ترکیبی دیگر که نتایج چشمگیری در استفاده از روش های ارزیابی دارد، در [۲۰] ارائه شده است. این تحقیق از شبکه عصبی تابع پایه شعاعی<sup>۹</sup> برای پیش بینی بارش باران با استفاده از روش بهینه سازی ترکیبی دو الگوریتم تکاملی و هوش ازدحامی ژنتیک و ازدحام ذرات بهینه<sup>۱۰</sup>، استفاده می کند.

### ۳-۱- رویکرد پیشنهادی

داده ورودی، داده ای نرمال سازی شده می باشد. در ابتدا، مدل سازی داده انجام می شود. این که چرا می بایست مدل سازی پارامتری داده را در شبکه های پیچیده انجام بدهیم، به این دلیل است که داده به صورت نگاشت، انجام شود و ویژگی های آن استخراج گردد و یک چارچوب برای کارهای آتی، صورت پذیرد. این عملیات در زمان کنترل داده ها مورد نیاز می باشد. حال اگر این داده ها باعث تغییر دامنه گردد، داده ها به شدت افزایش می یابد. پس در ابتدا به مدل سازی پارامتری داده می پردازیم که بتوان بر اساس ساختار سیستم های پیچیده و تئوری کنترل پذیری، چارچوب ارائه شود. در مدل سازی پارامتری

<sup>۱</sup> منظور از آئروسول، ذرات گرد و غبار معلق در هوا است (Aerosol).

<sup>۲</sup> Feed-Forward Neural Network (FF NN)

<sup>۳</sup> Multi Layered Feed-Forward Neural Network (MFF NN)

<sup>۴</sup> Moving Average Neural Network (MA NN)

<sup>۵</sup> Singula Spectrum Neural Network (SS NN)

<sup>۶</sup> Wavelet Transform

<sup>۷</sup> ANFIS

<sup>۸</sup> Association Rules

<sup>۹</sup> Radial Basis Function (RBF)

<sup>۱۰</sup> Particle Swarm Optimization (PSO)

داده، داده با یک مدل ریاضی نمایش داده می شود که یک ساختار از پیش تعریف شده و تعداد محدود پارامتر دارد. داده  $s[n]$  باید با انتخاب این پارامترها مشخص شود، به نحوی که خروجی مدل  $\hat{s}[n]$  تا حد ممکن به داده ورودی نزدیک باشد. داده با استفاده از مقادیر  $a_k$  و  $b_k$  یا به طور معادل با قطب ها و صفرهای  $H(z)$  و ورودی، مدل می شود. این داده ورودی  $v[n]$  معمولا برای داده های تعینی یک ضربه واحد  $\delta[n]$  و برای حالتی که داده به صورت تصادفی است، نویز در نظر گرفته می شود. پس از انتخاب مناسب مدل، می توان نمونه های متعددی از داده را با مجموعه نسبتا کوچکی از پارامترها نمایش داد. مدل کردن پارامتریک داده، کاربردهای گسترده ای دارد که از جمله آن ها می توان به فشرده سازی داده، تحلیل طیفی، پیش بینی داده، دی کانولوشن، طراحی فیلتر، تشخیص سیستم، طبقه بندی داده و غیره اشاره کرد. رویکرد روش ارائه شده در این پژوهش، پیش بینی بارش باران در یک منطقه در یک برهه زمانی مشخص می باشد که از جمله عملیات مدل سازی پارامتریک داده به شمار می رود. روش مدل سازی پارامتریک داده با هدف تخمین و پیش بین در شبکه های پیچیده، تقریب کمترین مربعات می باشد. هدف این مدل سازی این است که ورودی  $v[n]$  و پارامترهای  $G$  و  $a_1, \dots, a_n$  در رابطه (۱) طوری برگزیده شود که  $\hat{s}[n]$  تقریب خوبی از  $s[n]$  باشد.

$$\hat{s}[n] = \sum_{k=1}^p a_k \hat{s}[n-k] + Gv[n] \quad (1)$$

بر طبق رابطه (۱) معمولا  $v[n]$  از قبل مشخص است و در این صورت روش مستقیم تعیین بهترین مقدار برای پارامترها می تواند به حداقل رساندن کل داده خطای  $e_{se}[n] = (s[n] - \hat{s}[n])$  باشد و به این ترتیب، تقریب کمترین مربعات برای  $s[n]$  به دست می آید. مشخصا برای داده های تعینی، پارامترهای مدل را می بایست طوری انتخاب کرد که مربع خطای کل، به حداقل برسد. رابطه اصلی به صورت رابطه (۲) می باشد.

$$\sum_{n=-\infty}^{\infty} (s[n] - \hat{s}[n])^2 = \sum_{n=-\infty}^{\infty} (s[n] - a_k \hat{s}[n-k] + Gv[n])^2 \quad (2)$$

برای یافتن ضرایب  $a_k$ ، حداقل کننده این خطا باید از معادله (۲) نسبت به هر پارامتر، مشتق گرفت. سپس مشتق ها را برابر صفر قرار داد و معادله را حل کرد. چنین کاری یک دسته غیرخطی را نتیجه می دهد که یافتن جواب آن عموما دارای مشکلاتی است. به همین دلیل ما به منظور کاهش محاسبات و جلوگیری از پیچیدگی محاسباتی، از نگاشت آشوب ناک مدل طیفی خطی استفاده خواهیم کرد. در واقع نظریه آشوب با ویژگی های خود، در این رهیافت می نشیند. بدین صورت که نگاشت ها، بر اساس بردارها از داده، در گره های شبکه پیچیده تولید می کنند و با حلقه قرار دادن آن ها، شروع به یافتن ضرایب  $a_k$  خواهند کرد. یک توزیع برای حل مسئله مورد نیاز می باشد، پس می توان به جای استفاده از روش های توزیع آمار و احتمالاتی چون توزیع لیپانوف<sup>۱</sup> و غیره، از توزیع پواسون<sup>۲</sup> استفاده کرد که رابطه آن به صورت (۳) می باشد.

$$PR(r) = \frac{2r}{\Omega} e^{-r^2/\Omega}, r \geq 0, \quad \text{where } \Omega = E(R^2) \quad (3)$$

تمامی مقادیر به دست آمده را بر حسب دسی بل به دست می آوریم و از واحدهایی دیگر استفاده نمی کنیم. حال با استفاده از نگاشت داده ها، می خواهیم از اوج حداکثر ریشه میانگین خطا، تخمین دیگری به دست آوریم. دو نوع مختلف از داده ها به یک داده که نرمال شده است، با استفاده از نگاشت های آشوب ناک یعنی مدل طیفی خطی، نسبت داده می شوند و پس از حلقه آشوب مبنی بر مدل سازی پارامتری داده فرکانس، اختلاف برای تخمین به دست می آید. برای هر داده  $x(t)$  رابطه به صورت (۴) می باشد.

$$X_t \text{ data} = \frac{\max[x(t)x \times(t)]}{E(x(t)x \times(t))} \quad (4)$$

<sup>1</sup> Lyapanov Process

<sup>2</sup> Poisson Process

## سومین همایش ملی مهندسی کامپیوتر، داده کاوی و داده های حجیم

در این بخش از روشی به نام درخت تصمیم دودویی استفاده می شود که به صورت بازگشتی از آن استفاده خواهد شد. است. واژه بازگشتی از یک واقعیت که ماتریس بهینه توسط هر نگاشت و بردار تولید شده ورودی به روز رسانی شده باشد، می آید. می بایست دقت کرد که ماتریس در دامنه درخت ایجاد می شود. در شمای درخت تصمیم دودویی بهینه نگاشت انتخابی، در ابتدا ماتریس داده دامنه درخت ایجاد شده با داده های نگاشت در شبکه های پیچیده به صورت آفلاین تولید می شود و در جدول مشاهداتی<sup>۱</sup> جمع آوری می گردد. اندازه این ماتریس بستگی به تعداد نمونه های نگاشت از بردار انتخابی دارد که برای کاربرد خاصی و تعداد زیر  $N$  ویژگی تخصیص می یابد. با تولید داده ورودی، هر سطر از این ماتریس در چرخه بازگشتی انتخاب خواهد شد. بردار انتخابی از ماتریس در دامنه زمانی درخت به صورت دودویی تبدیل خواهد شد که این کار توسط یک واحد دودویی و مقدار داده نگاشت از همان ماتریس انجام می شود و انتظار می رود که یک داده نگاشت شده با حداقل عملیات محاسباتی در بخش تخمین و پیش بینی، در نهایت تولید شود. عناصر یک ماتریس درخت تصمیم دودویی بهینه به صورت رابطه (۵) خواهد بود.

$$\hat{X} = \hat{B} \times X \quad (5)$$

که در رابطه (۵)،  $\hat{B}$  توالی فاز بهینه است که از ماتریس توالی فاز تولید می شود و  $X$  هم داده ورودی (نگاشت شده) است. یک ماتریس درخت تصمیم دودویی بهینه به صورت آفلاین انجام می شود که ماتریس توالی فاز بهینه در ابتدا برپایه روش نگاشت انتخابی به صورت رابطه (۶) ایجاد می شود.

$$\hat{B} = \begin{bmatrix} B_{1,1} & B_{1,2}, \dots & B_{1,N} \\ B_{U,1} & B_{U,2}, \dots & B_{U,N} \end{bmatrix}_{U \times N} \quad (6)$$

که در رابطه (۶)،  $U$  تعداد زیر بلاک ها و  $N$  اندازه بردارهای نگاشت شده است. اگر ماتریس در رابطه (۲) با عدد بالاتری از زیر بلاک ها یعنی مقدار  $U$  ایجاد شود، کارایی نگاشت در داده های شبکه پیچیده بهتر خواهد شد. برپایه توالی فاز بهینه در رابطه (۶)، داده های بهینه نگاشت شده ماتریس درخت تصمیم دودویی بهینه به صورت آفلاین محاسبه خواهد شد. ایده اصلی برای پیاده سازی این شماتیک، استخراج جریان داده است، زیرا جریان داده ورودی به بردار از پیش محاسبه شده انتقال می یابد که به صورت آفلاین تولید گردیده است. به منظور فراهم کردن چنین محیطی، بردار توالی فاز به بدست آوردن هر زمانی از تولید داده نگاشت ورودی می پردازد. توالی فاز به صورت رابطه (۷) خواهد بود.

$$B = \hat{X} \times \frac{1}{X} \quad (7)$$

که در رابطه (۷)،  $\hat{X}$  بردار نگاشت ورودی بهینه با حداقل مقدار داده در داده های کنترلی و توزیع پواسون در داده های نگاشت شده است و  $X$  نمایش داده ورودی است. می بایست توجه کرد که توالی فاز محاسبه شده از رابطه (۷) جهت به دست آوردن نگاشت های بردار از داده برطبق معیار آستانه از پیش تعریف شده، دوباره بررسی می شود. یعنی در یک چرخه قرار می گیرد. با انتقال بردار توالی فاز به عنوان اطلاعات جانبی در امتداد ورود نگاشت، داده اصلی می تواند در تخمین، شرکت نماید. اگر داده به صورت نگاشت شده استاندارد باشد و دارای دوره تناوب باشد، رابطه (۸) وجود خواهد داشت و به منظور به دست آوردن مقدار اوج سیگنال از داده رابطه (۹) وجود دارد و مقدار میانگین مربعات سیگنال از داده نیز به صورت رابطه (۱۰) است.

$$x(t) = \sin(2\pi ft) \quad (8)$$

$$\max[x(t)x \times (t)] = 1 \quad (9)$$

<sup>1</sup> Look-Up Table (LUT)

## سومین همایش ملی مهندسی کامپیوتر، داده کاوی و داده های حجیم

$$E[x(t)x \times (t)] = \frac{1}{T} \int_0^T \sin^2(2\pi ft) = \frac{1}{2} \quad (10)$$

از رابطه (۱۰) و خلاصه نویسی آن می توان رابطه تخمین و توزیع پواسون آن برای گره ها در شبکه پیچیده را به دست آورد که به صورت رابطه (۱۱) می باشد.

$$CF = \frac{1}{(\frac{1}{2})} = 2 \quad (11)$$

داده نگاشت شده ورودی در یک درخت می باشد، پس نیاز است داده انتقالی درخت (که نوع آن را به صورت دودویی مشخص کرده ایم) نیز به دست آید که از رابطه (۱۲) ناشی می شود.

$$x(t) = \sum_0^{k-1} a_k e^{\frac{j2\pi kt}{T}} \quad (12)$$

طبق رابطه (۱۲)، برای سادگی انتقال داده نگاشت شده، برای همه درخت ها فرض می شود که  $a_k = 1$  است. با توجه به این رویکرد، به منظور به دست آوردن مقدار اوج سیگنال جهت تخمین، از رابطه (۱۳) استفاده می شود.

$$\begin{aligned} \max[x(t)x \times (t)] &= \max[\sum_0^{k-1} a_k e^{\frac{j2\pi kt}{T}} \sum_0^{-1} a_k e^{\frac{-j2\pi kt}{T}}] = \\ \max[a_k a_k \sum_0^{k-1} \sum_0^{k-1} e^{\frac{j2\pi kt}{T}} - e^{\frac{-j2\pi kt}{T}}] &= K^2 \end{aligned} \quad (13)$$

و مقدار میانگین مربعات سیگنال نیز به صورت رابطه (۱۴) خواهد بود.

$$E[x(t)x \times (t)] = E[\sum_0^{k-1} a_k e^{\frac{j2\pi kt}{T}} \sum_0^{-1} a_k e^{\frac{-j2\pi kt}{T}}] = E[a_k a_k \sum_0^{k-1} \sum_0^{k-1} e^{\frac{j2\pi kt}{T}} - e^{\frac{-j2\pi kt}{T}}] = K \quad (14)$$

از رابطه (۱۳) و رابطه (۱۴) رابطه (۱۵) حاصل می شود که مقدار پیش بینی برای نگاشت داده پیچیده است.

$$CF = \frac{K^2}{K} = K \quad (15)$$

داده نگاشت ورودی در درخت در چارچوب شبکه پیچیده نیز بر اساس به صورت رابطه (۱۶) می باشد.

$$CF(dB) = 20 \log\left(\frac{V_{pev}}{V_{rms}}\right) = 10 \log\left(\frac{P_{PEP}}{P_{AVG}}\right) \quad (16)$$

طبقه رابطه (۱۶)،  $P_{PEP}$  اوج فشار است که معادل رویکرد انولاپ می باشد که از روش اوج توان میانگین به دست می آید که آن هم بر اساس رویکرد حامل می باشد.  $P_{AVG}$  توان میانگین سیگنال داده می باشد که از تقسیم مرتبه توان دوم سیگنال نگاشت شده از داده به دست می آید. توان میانگین یک چرخه از نگاشت داده درختی برابر با کل توان میانگین آن داده می باشد. داده ها در درخت به صورت رابطه (۱۷) نشان داده می شود.

$$x(t) = \frac{1}{\sqrt{N}} \sum_{a=0}^{N-1} X_a e^{j2\pi \frac{a}{N} t}, \quad 0 \leq t \leq N-1 \quad (17)$$

که طبق رابطه (۱۷)،  $X = [X_0, X_1, \dots, X_{N-1}]$  توالی نگاشت داده ورودی است. هرگاه که  $N$  افزایش یابد، هر دو بخش واقعی و موهومی از داده نگاشت شده با رویکرد درخت تصمیم دودویی با مقدار صفر و واریانس  $1/2$  توسط قضیه حد

## سومین همایش ملی مهندسی کامپیوتر، داده کاوی و داده های حجیم

مرکزی، تخمین و پیش بینی می شود. بنابراین، مقدار داده های درختی دارای یک توزیع پواسون نیز هستند و همین طور یک توزیع خی دو<sup>۱</sup> با دو درجه آزادی و مقدار صفر است. توزیع پواسون در زیر داده نمونه برداری شده به صورت رابطه (۱۸) می باشد.

$$Pr(data \leq data_0) = (1 - exp(-data))^2 \quad (18)$$

بنابراین مکمل این تابع، داده های نگاشت شده در توزیع پواسون مبتنی بر توزیع خی دی برای داده های موجود در شبکه های پیچیده در درخت به صورت رابطه (۱۹) می باشد.

$$Pr(data \leq data_0) = 1 - (1 - exp(-data_0))^{aN} \quad (19)$$

این روش احتمال آماری وقوع اوج های داده بزرگ تر از مقدار میانگین به ازای نسبت های مختلف می باشد. فرض می شود یک سیکل پرپودیک مانند  $x_0, x_1, \dots, x_{p-1}, x_p = x_0$  در اختیار است. یعنی اگر از هر یک از این نقاط شروع کنیم، پس از  $p$  بار باید به جای اولیه بازگشت. اکنون فرض می شود از این شرط اولیه به میزان  $\delta_0$  دور شد. در این صورت پس از  $p$  بار میزان انحراف به اندازه  $\delta_p$  خواهد بود که روابط (۲۰) وجود دارد.

$$\begin{aligned} x_0 &= x_j + \delta_0 \\ x_p &= x_j + \delta_p \\ x_j + \delta_p &= M^P(x_j + \delta_0) \end{aligned} \quad (20)$$

چون  $\delta_0$  کوچک است، اگر از بسط تیلور<sup>۲</sup> مرتبه اول استفاده شود، رابطه (۲۱) وجود دارد.

$$\begin{aligned} \delta_p &= \lambda_p \delta_0 \\ \lambda_p &= \frac{dM^P(x)}{dx} \Big|_{x=x_j} = \frac{dx_{n+p}}{dx_n} \Big|_{x=x_j} \end{aligned} \quad (21)$$

با استفاده از رابطه (۲۲) می توان همه چرخه های آشوب ناک در تولید درخت ها در تخمین و پیش بینی آب و هوا با هدف بارش باران را یکسان نمود و یک نتیجه کلی از آن به دست آورد.

$$\frac{dx_{n+p}}{dx_n} = \frac{dx_{n+1}}{dx_n} \cdot \frac{dx_{n+2}}{dx_{n+1}} \dots \frac{dx_{n+p}}{dx_{n+p-1}} = M'(x_n)M'(x_{n+1}) \dots M'(x_{n+p-1}) \quad (22)$$

به این ترتیب  $\lambda_p$  برای تمام نقاط روی چرخه آشوب ناک درخت ها یکسان بوده و برابر است رابطه (۲۳).

$$\lambda_p = M'(x_0)M'(x_1) \dots M'(x_{p-1}) \quad (23)$$

اکنون اگر همین چرخه آشوب ناک درخت را  $m$  بار دیگر نیز تکرار کنیم، این خطاها در همدیگر ضرب شده و رابطه (۲۴) وجود خواهد شد.

$$\delta_{mp} = \lambda_p^m \delta_0 \quad (24)$$

حال یک تخمین و پیش بینی مناسب در پیش بینی آب و هوا با هدف بارش باران در برهه زمانی، انجام می شود.

## ۴- شبیه سازی و نتایج حاصل

در ابتدا شایان ذکر است که از مجموعه داده های تهران در سال ۱۳۹۶ استفاده می شود و قرار است آب و هوای تهران جهت پیش بینی دقیق بارش باران در یک سال بعد، یعنی سال ۱۳۹۷، تخمین و پیش بینی گردد. داده موجود، داده بزرگ<sup>۳</sup> است. شکل (۱)، بخشی از این داده بزرگ را نشان می دهد.

<sup>1</sup> Chi-Square Distribution

<sup>2</sup> Taylor

<sup>3</sup> Big Data



## سومین همایش ملی مهندسی کامپیوتر، داده کاوی و داده های حجیم

row	col1	col2	col3
1	7.3450404169999994e+05	6.3601532567049801e-01	0.0000000000000000e+00
2	7.3450408330000006e+05	6.3601532567049801e-01	0.0000000000000000e+00
3	7.3450412500000000e+05	6.3601532567049801e-01	0.0000000000000000e+00
4	7.3450416669999994e+05	6.3601532567049801e-01	0.0000000000000000e+00
5	7.3450420830000006e+05	6.3601532567049801e-01	0.0000000000000000e+00
6	7.3450425000000000e+05	6.3601532567049801e-01	0.0000000000000000e+00
7	7.3450429169999994e+05	6.3601532567049801e-01	0.0000000000000000e+00
8	7.3450433330000006e+05	6.3601532567049801e-01	0.0000000000000000e+00
9	7.3450437500000000e+05	6.3601532567049801e-01	0.0000000000000000e+00
10	7.3450441669999994e+05	6.3601532567049801e-01	0.0000000000000000e+00
11	7.3450445830000006e+05	6.3601532567049801e-01	0.0000000000000000e+00
12	7.3450450000000000e+05	6.3601532567049801e-01	0.0000000000000000e+00
13	7.3450454169999994e+05	6.3601532567049801e-01	0.0000000000000000e+00
14	7.3450458330000006e+05	6.3601532567049801e-01	0.0000000000000000e+00
15	7.3450462500000000e+05	6.3601532567049801e-01	0.0000000000000000e+00
16	7.3450466669999994e+05	6.3601532567049801e-01	0.0000000000000000e+00
17	7.3450470830000006e+05	6.3601532567049801e-01	0.0000000000000000e+00
18	7.3450475000000000e+05	6.3601532567049801e-01	0.0000000000000000e+00
19	7.3450479169999994e+05	6.3601532567049801e-01	0.0000000000000000e+00
20	7.3450483330000006e+05	6.3218390804597713e-01	0.0000000000000000e+00

شکل (۱) بخشی از داده های ورودی

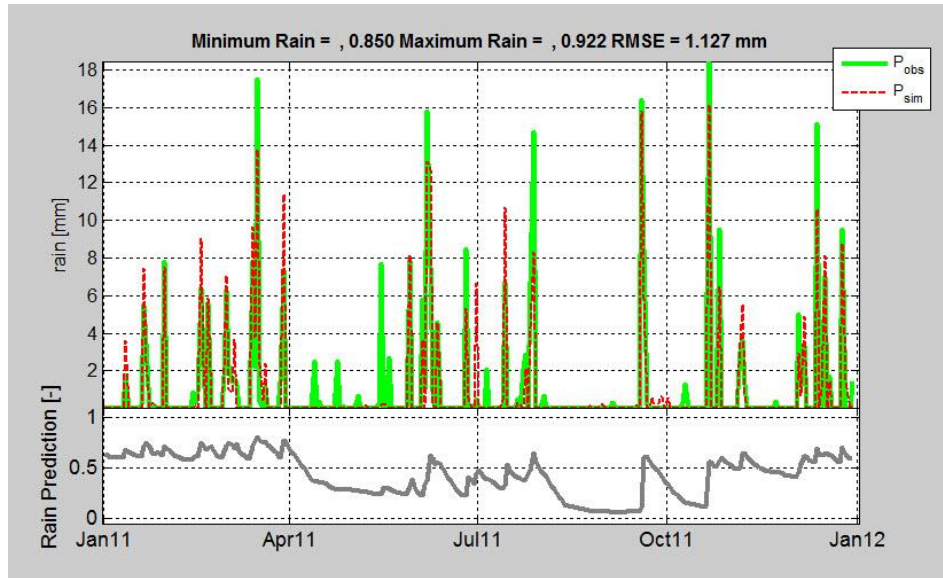
این مجموعه داده دارای ۳ ستون و ۸۸۷۵۹ سطر می باشد. واضح و مبرهن است که داده به عنوان یک داده بزرگ شناخته می شود. زمانی که شبیه سازی اجرا می شود، ۱۴ دور دور تکرار جهت تخمین و پیش بینی میزان بارش باران شکل می گیرد و یک سری نتایج اولیه از آن استخراج می شود که در جدول (۱) آورده شده است.

جدول (۱) نتایج در ۱۴ دور اجرا

دور تکرار	تعداد ویژگی در هر کلاس	تابع F(x)	بیشترین محدودیت ها	جستجوی خطی بر حسب اندازه گام	مشق جهت دار در تخمین مبتنی بر نگاهت های آشوب ناک	رویه بهینه سازی
۱	۴	۰,۱۹۷۸۰۶	-۰,۰۲	۰,۰۶۲۵	-۲,۱	۲,۶۳
۲	۱۲	۰,۱۶۵۳۷	-۰,۰۱۸۷۵	۰,۲۵	-۰,۳۶۴	۰,۹۶۳
۳	۱۸	۰,۱۶۵۳۱۱	-۰,۰۱۴۰۶	۰,۱۲۵	-۰,۸۲۴	۰,۲۴۸
۴	۲۵	۰,۱۵۲۸۱۵	-۰,۰۲۸۱۳	۰,۰۶۲۵	-۰,۲۲۱	۰,۱۹
۵	۳۳	۰,۱۵۱۸۳۷	-۰,۰۲۷۲۴	۱	-۰,۰۸۶	۰,۰۹۴۷
۶	۳۷	۰,۱۵۱۴۸۳	-۰,۰۲۴۲۳	۰,۲۵	-۰,۰۶۷۱	۰,۲۲۹
۷	۴۳	۰,۱۵۱۰۲۳	-۰,۰۱۸۱۷	۱	-۰,۰۵۴	۰,۲۶۱
۸	۴۷	۰,۱۵۰۷۹۴	-۰,۰۱۶۰۳	۱	-۰,۰۸۳	۰,۲۳۶
۹	۵۱	۰,۱۵۰۴۶	-۰,۰۱۳۶۹	۰,۵	-۰,۰۵۴۳	۰,۲۳۶
۱۰	۵۶	۰,۱۵۰۲۵۸	-۰,۰۱۰۵۹	۱	-۰,۰۷۵۴	۰,۰۲۰۹
۱۱	۶۰	۰,۱۵۰۱۷۹	-۰,۰۱۱۳۸	۱	-۰,۰۱۴	۰,۰۵۷۸
۱۲	۶۴	۰,۱۵۰۱۵	-۰,۰۱۰۲۷	۱	-۰,۰۰۷۸۱	۰,۰۴۳۳
۱۳	۶۸	۰,۱۵۰۱۴۱	-۰,۰۰۹۸۳۱	۱	-۰,۰۰۷۳۷	۰,۰۱۰۹
۱۴	۷۲	۰,۱۵۰۱۳۹	-۰,۰۰۹۷۵۸	۱	-۰,۰۰۱۲۹	۰,۰۰۱۳۱
۱۵	۷۶	۰,۱۵۰۱۳۹	-۰,۰۰۹۶۷۴	۱		

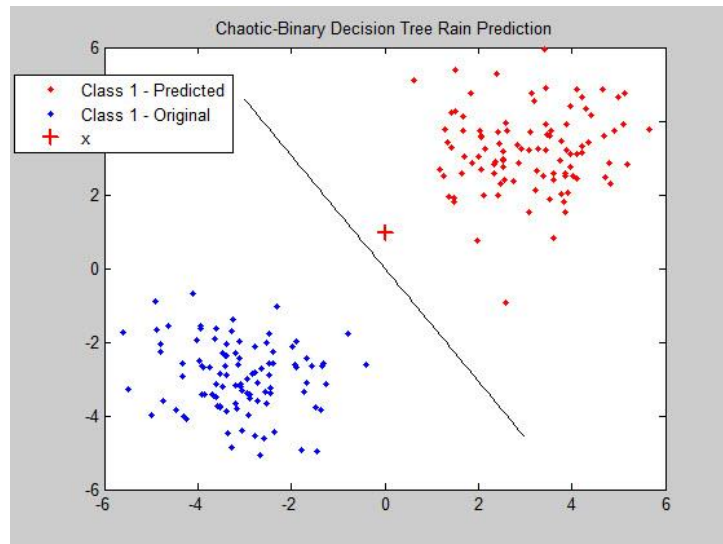
## سومین همایش ملی مهندسی کامپیوتر، داده کاوی و داده های حجیم

خروجی در زمان شبیه سازی برای تخمین و پیش بینی باران به شکل (۲) می باشد.



شکل (۲) تخمین و پیش بینی باران مبتنی بر روش پیشنهادی

بر اساس شکل (۲)، از ۱۱ ژانویه الی ۱۲ ژانویه سال بعد به مدت تخمین یک سال، تخمین و پیش بینی آب و هوا با هدف بارش باران انجام شده است. نمودار سبز رنگ، میزان باران مشاهده شده و جمع آوری شده در این بازه را نشان می دهد. همچنین نمودار قرمز رنگ، مقدار پیش بینی برای ماه ژانویه برای سال دیگر را نشان می دهد. بیشترین میزان بارش که در داده ها ثبت شده است، در ماه اکتبر با ۱۸ میلی متر است و بیشترین مقدار پیش بینی شده هم دقیقاً در همان روز از ماه اکتبر با ۱۷ میلی متر مدنظر واقع شده است. البته در اوایل ماه اکتبر نیز همین میزان اما به طور دقیق تر ۱۵,۹ میلی متر، پیش بینی انجام گرفته است. میزان ریشه میانگین مربعات خطا هم در روش پیشنهادی برابر با ۱,۱۲۷ میل متر برای پیش بینی بارش باران می باشد. خروجی بخش طبقه بندی داده ها نیز نشان داده شده است که می توان در شکل (۳) آن را مشاهده نمود.



شکل (۳) خروجی بخش طبقه بندی داده ها در زمان پیش بینی و داده های اصلی

همچنین نتایج ارزیابی نیز به صورت کلی در جدول (۲) ارائه شده است. قابل ذکر است که این مقادیر بعد از ۱۰ بار اجرای روش و خروجی گرفتن و میانگین گیری، ثبت شده است.

## سومین همایش ملی مهندسی کامپیوتر، داده کاوی و داده های حجیم

جدول (۲) نتایج ارزیابی روش پیشنهادی

Sensitivity (%)	Accuracy (%)	SNR (dB)	PSNR (dB)	RMSE	MSE
۶۴,۵۴۷۴	۹۹,۱۰۹۸	۱۵,۰۸۶۴	۶۳,۲۱۷۲	۱,۱۲۷	۰,۰۳۱۰

بر اساس نتایجی که حاصل شد، می توان به تضمین روش پیشنهادی استناد نمود که دارای نتایج چشمگیری می باشد و می تواند به عنوان یک سیستم پیش بینی بارش باران در یک ماه از یک سال، مورد استفاده واقع گردد. همچنین یک مقایسه موردی بین [۱۱] و [۱۵] با رویکرد پیشنهادی انجام گرفته است. بر اساس این نتایج، میزان عملکرد این دو رویکرد پیشین بر اساس معیار دقت بر حسب درصد، با روش پیشنهادی این تحقیق، انجام گرفته است. این نتایج در جدول (۳) نشان داده شده است.

جدول (۳) مقایسه نتایج ارزیابی

دقت (بر حسب درصد)	رویکردها
۹۲,۰۱۴۰	روش مقاله [۱۱]
۹۴,۲۲۰۳	روش مقاله [۱۵]
۹۹,۱۰۹۸	رویکرد پیشنهادی این تحقیق

بر اساس نتایج موجود، نشان داده شده است که روش پیشنهادی دارای بهبود عملکردی از لحاظ دقت در پیش بینی بارش باران از یک مجموعه داده می باشد.

### ۵- نتیجه گیری

امروزه با رشد فناوری های مربوط در زمینه هواشناسی و گسترش استفاده از تجهیزات الکترونیکی، ابزارهای مختلفی در حوزه هواشناسی ایجاد گردیده است. با توجه به این که آب و هوا یکی از اصول مهم و تاثیرگذار در همه کشورهای دنیا می باشد، نیاز است تا بتوان بر اساس روش های اندازه گیری جدید، یک تخمین و پیش بینی آب و هوا به دست آورد. اندازه گیری این تخمین و پیش بینی، می تواند یک کشور را در رسیدن به اهدافشان، سوق بدهد. بارش باران یک عنصر مهم از منابع آبی در تمام نقاط جهان از جمله مناطق خشک و نیمه خشک می باشد. بارندگی یکی از پیچیده ترین و اتفاقی ترین پدیده های طبیعی می باشد. در واقع تاثیر عوامل محسوس و یا غیر محسوس آن چنان در ایجاد حادثه دخیل است که این روند را از یک نظام قانونمند روشن به سوی یک ساختار پیچیده و آشوبناک سوق داده است. از آن جایی که ایران در اقلیم خشک و نیمه خشک واقع شده است، پیش بینی آب و هوا با هدف بارش باران برای برنامه ریزی و مدیریت منابع آب دارای اهمیت است. تصمیم گیرنده های منابع آب نیاز به پیش بینی مطمئنی برای تصمیم گیری های مدیریتی دارند. در این بین روش های پیش بینی مختلفی سعی در تعیین ارتباط بین متغیرهای مستقل و وابسته داشته اند و مدل های مفهومی و آماری زیادی برای پیش بینی و پیش آگاهی متغیرهای اقلیمی مورد استفاده قرار گرفته است. محققین با اتخاذ شیوه های مختلف درصد برآمده اند تا نتایج قابل قبولی را در این زمینه برای نقاط مختلف دنیا به دست آورند. برنامه ریزی، توسعه، مدیریت و بهره برداری بهینه از سیستم های منابع آب به اطلاعات متنوع و متعددی در زمینه های هواشناسی، هیدرولوژی، اقتصادی، اجتماعی و غیره، نیازمند می باشد. در این میان، ریزش های جوی خصوصا بارندگی یکی از مهمترین فرایندهای چرخه هیدرولوژی بوده که تنها در صورت وقوع آن فرایندهایی نظیر سیلاب، فرسایش، رسوب گذاری، آلودگی آب های سطحی و زیرزمینی و غیره به وقوع می پیوندد. این فرایند از بیشترین تغییرات مکانی و زمانی برخوردار بوده و کمیت بخشیدن به آن در مکان و زمان همواره مورد توجه محققین مختلف بوده است. پیش بینی وضعیت بارش در منابع آب نقش بسیار حیاتی به عهده دارد. روش های متداول

در پیش بینی پارامترهای هواشناسی که امروزه مورد استفاده قرار می گیرد، با توجه به احتمال خطای انسانی و دقت پایین و همچنین داشتن حجم انبوهی از داده ها و محاسبات حجیم، دارای محدودیت می باشند. امروزه محققین با ابداع و پیشرفت علمی چون روش های هوشمند که ابزاری توانمند و انعطاف پذیر و مستقل از مدل های دینامیکی سیستم هستند، گام هایی را در راه شناخت و پیش بینی پارامترهای مهم هواشناسی برداشته اند. به منظور تخمین و پیش بینی آب و هوا با هدف بارش باران، از مجموعه داده های قبلی که میزان آب در منطقه را ذخیره نموده اند، به عنوان داده های ورودی استفاده می شود. نیاز است تا از این داده ها، یک سری اطلاعات استخراج شود. به روند استخراج اطلاعات از داده ها، داده کاوی گفته می شود که این تحقیق نیز اساس و بنیانی در حوزه داده کاوی دارد. بعد از نرمال سازی داده ها، استفاده از سیستم های پیچیده همراه با تئوری کنترل پذیری، به عنوان یک چارچوب مناسب، ویژگی ها را شناسایی می کنند و با استفاده از نظریه آشوب و نگاشت های آشوب ناک، ویژگی ها استخراج می شوند که مبتنی بر توزیع پواسون، توزیع خی دو و بسط تیلور مرتبه اول، این کارها انجام می شود. این عملیات به صورت کلی، مدل طیفی خطی نام دارند. در ادامه از روش تصمیم گیری مبتنی بر درخت تصمیم دودویی به صورت بهینه برای تخمین و پیش بینی آب و هوا با هدف بارش باران، استفاده می شود. رویکرد پیشنهادی نشان داد که توانایی پاسخ به سوالات تحقیق را داشته است و دارای عملکرد بالاتری نسبت به روش های پیشین می باشد.

### ۶-مراجع

- [1]. Shojaee, Parizad Nasirabadi, Mostafa Ghiaasiaan, S., and Henri Hattel, Jesper. (2019). Long term prediction of local climate inside an electronics enclosure. *International Journal of Heat and Mass Transfer*, Vol. 137, pp. 280-291.
- [2]. Turco, Marco, Marcos-Matamoros, Raúl, Castro, Xavier, Canyameras, Esteve, and Carmen Llasat, Maria. (2019). Seasonal prediction of climate-driven fire risk for decision-making and operational applications in a Mediterranean region. *Science of the Total Environment*, Vol. 676, pp. 577-583.
- [3]. N. Brown, Jaclyn, Hochman, Zvi, Holzworth, Dean, and Horan, Heidi. (2018). Seasonal climate forecasts provide more definitive and accurate crop yield predictions. *Agricultural and Forest Meteorology*, Vol. 260-261, pp. 247-254.
- [4]. P. Fowdur, T., Beeharry, Y., Hurbungs, V., Bassoo, V., Ramnarain-Seetohul, V., and Chan MooLun, E. (2018). Performance analysis and implementation of an adaptive real-time weather forecasting system. *Internet of Things*, Vol. 3-4, pp. 12-33.
- [5]. Ponce, Hiram, and Gutiérrez, Sebastián. (2019). An indoor predicting climate conditions approach using Internet-of-Things and artificial hydrocarbon networks. *Measurement*, Vol. 135, pp. 170-179.
- [6]. Olaiya, Folorunsho, and Adeyemo, Adesesan Barnabas. (2012). Application of Data Mining Techniques in Weather Prediction and Climate Change Studies.
- [7]. Gill, Jasmineen, Singh, Baljeet and Singh, Shaminder (2010) Training Back Propagation Neural Networks with Genetic Algorithm for Weather Forecasting. *IEEE 8th International symposium on intelligent systems and informatics Serbia*.
- [8]. Agboola, A. H., Gabriel, A. J., Aliyu, E. O., and Alese, B. K. (2013). Development of a Fuzzy Logic Based Rainfall Prediction Model. Vol. 3 No. 4.
- [9]. Somia, A. Asklany, Elhelow, Khaled, Youssef, I. K., and Abd El-wahab, M. (2011). Rainfall events prediction using rulebased fuzzy inference system.
- [10]. Geetha, G., and Selvaraj, R. S. (2011). Prediction of monthly rainfall in Chennai using Back Propagation Neural Network model. *Int. J. of Eng. Sci. and Technology*. Vol. 3, No. 1, pp. 211-213.
- [11]. Shrivastava, G., Karmakar, S., and M. K. Kowar. (2013). BPN model for longrange forecast of monsoon rainfall over a very small geographical region and its verification for 2012. *Geofizika*, Vol. 30, No. 2, pp. 155-172.
- [12]. Priya, Shilpi Vashistha, and Singh, V. (2014). Time Series Analysis of Forecasting Indian Rainfall. *Int. J. of Innovations & Advancement in Comput. Sci*. Vol. 3, No. 1, pp. 66-69.
- [13]. Naik, A. R., and Pathan, S. K. (2013). Indian monsoon rainfall Classification And Prediction using Robust Back Propagation Artificial Neural Network. *Int. J. of Emerging Technology and Advanced Eng*. Vol. 3, No. 11, pp. 99-101.

- [14]. Wu, C. L, and Chau, K. W. (2013). Prediction of rainfall time series using modular soft computing methods. *Eng. Applicat. of Artificial Intell.* Vol. 26, No. 3, pp. 997-1007.
- [15]. Dabhi, V. K., and Chaudhary, S. (2014). Hybrid Wavelet-Postfix-GP model for rainfall prediction of Anand region of India. *Advances in Artificial Intell.*, pp. 1-11.
- [16]. Alvisi, S., Mascellani, G., Franchini, M. and Bárdossy, A. (2006). Water level forecasting through fuzzy logic and artificial neural network approaches. Copernicus GmbH.
- [17]. Bhuwana, Vidi, (2014). Rainfall Runoff Modeling by Using Adaptive Network-Based Fuzzy Inference System (ANFIS). Case Study Ciliwung River.
- [18]. Vathsala, H., and Koolagudi, Shashidhar G. (2017). Prediction model for peninsular Indian summer monsoon rainfall using data mining and statistical approaches. *Computers & Geosciences*, Vol. 98, pp. 55-63.
- [19]. Altunkaynak, Abdusselam, and Nigussie, Tewodros Assefa. (2015). Prediction of daily rainfall by a hybrid wavelet-season-neuro technique. *Journal of Hydrology*. Vol. 529, Part 1, pp. 287-301.
- [20]. Wu, Jiansheng, Long, Jin, Liu, Mingzhe. (2015). Evolving RBF neural networks for rainfall prediction using hybrid particle swarm optimization and genetic algorithm. *Neurocomputing*, Vol. 148, pp. 136-142.