

## مقایسه الگوسازی بارندگی ماهانه با مدل‌های SVM و ANFIS (مطالعه موردی: شهر گنبد کاووس)

نسرین ضابط پیشخانی - سید مرتضی سیدیان<sup>2\*</sup> - علی حشمت‌پور<sup>3</sup> - حامد روحانی<sup>4</sup>

تاریخ دریافت: 1393/04/25

تاریخ پذیرش: 1393/12/25

### چکیده

بارش یکی از مهم‌ترین عوامل مورد استفاده در مطالعات منابع طبیعی، آب، هواشناسی و غیره است. تشخیص پیش‌بینی‌پذیری و شناخت عوامل تأثیرگذار بر فرآیند بارش با توجه به نوسان‌ها و بی‌نظمی‌های موجود در سری زمانی بارش اهمیت دارد. این تحقیق با روش‌های سامانه استنتاج فازی - عصبی تطبیقی (ANFIS) و ماشین بردار پشتیبان (SVM) بارش ماهانه شهر گنبد کاووس را الگوسازی کرده است. داده‌های مورد استفاده مربوط به سال‌های 2012-1995 است. 2 سری ورودی (ماهانه) شامل: 1- میانگین دما و رطوبت، سرعت باد و فشار 2- مقادیر متوسط بارش ماهانه ایستگاه‌های آبسنجی استان گلستان در نظر گرفته شد. نتایج نشان داد اگرچه دقت SVM بیشتر از ANFIS است، اما پیش‌بینی بارندگی با پارامترهای هواشناسی توسط هر دو مدل دارای دقت کمی است. نتایج پیش‌بینی بارش با بارندگی ایستگاه‌های منطقه برای هر دو روش قابل قبول است. ضریب تعیین و خطای RMSE در مرحله آزمون در روش SVM به ترتیب برابر 0/91 و 5/59 و در روش ANFIS برابر 0/87 و 7/06 است. تحلیل حساسیت نشان داد که رطوبت نسبی مهم‌ترین متغیر هواشناسی در پیش‌بینی بارندگی است. سه متغیر دیگر تأثیر یکسانی بر نتایج دارند. همچنین موثرترین ایستگاه در پیش‌بینی بارندگی تعیین شد. این پژوهش نشان داد که SVM عملکرد بهتری نسبت به ANFIS در پیش‌بینی بارندگی داشته است.

**واژه‌های کلیدی:** ایستگاه‌های بارندگی، پارامترهای هواشناسی، تحلیل حساسیت، هوش مصنوعی

### مقدمه

در سال‌های اخیر توجه به مدل‌های هوشمند به‌عنوان تکنیک‌های جدید و ابزاری توانمند در فرآیندهای هیدرولوژی نظیر پیش‌بینی بارندگی افزایش یافته است. زیرا این روش‌ها به‌عنوان یک جعبه سیاه مناسب، کمتر به ابزار و داده‌های مدل‌های فیزیکی نیاز داشته و قادر به مدل‌سازی فرآیند غیرخطی بارش می‌باشند (3). ماتر تا (14) با ترکیب شبکه عصبی مصنوعی و منطق فازی موفق به ساخت مدلی گردید که می‌توانست با در اختیار داشتن آمار بارندگی و برخی از خصوصیات فیزیکی حوضه، رواناب را در یک زمان مناسب پیش‌بینی کند و به‌منظور ایجاد سیستم‌های هشدار سیل مورد استفاده قرار گیرد. فیضی و همکاران (9)، توکار و سنتون (19) با شبکه عصبی به پیش‌بینی بارش پرداختند. نتایج نشان داد که مدل رواناب - بارش حاصل از شبکه‌های عصبی مصنوعی در مقایسه با دیگر روش‌های آماری دقت بیشتری داشته و زمان کمتری برای برازش مدل صرف می‌شود. ایلدرومی و همکاران (4) با استفاده از شبکه عصبی مصنوعی به پیش‌بینی بارش در سه منطقه شیراز، مشهد و کرمان پرداختند و با انجام آزمون همبستگی پیرسون از مجموعه عوامل اقلیمی غیربارشی پارامترهای مناسب مدل‌سازی بارش را مشخص کردند.

یکی از کارهای معمول در برنامه‌ریزی منابع آب، شبیه‌سازی یا ساختن مدلی از متغیرهای هیدرولوژیک مانند بارندگی، دبی رودخانه و جریان‌های سیلابی است. این پدیده‌ها متغیرهای تصادفی هستند. بارندگی یکی از عوامل مهم است که به‌طور مستقیم در چرخه‌ی هیدرولوژی دخالت دارد. بنابراین تحلیل و پیش‌بینی این عامل نقش مهمی در برنامه‌ریزی بهتر منابع آب، کشاورزی و غیره به‌ویژه در مناطق خشک و نیمه‌خشک دارد. کارشناسان کشاورزی به همین دلیل در سال‌های اخیر، توجه ویژه‌ای به مدل‌سازی، پیش‌بینی و شبیه‌سازی به‌عنوان راه‌هایی نوین در تجزیه و تحلیل بارندگی و بررسی اثر آن بر فعالیت‌های کشاورزی از خود نشان داده‌اند. ارتفاع و الگوی باران، جزء مهم‌ترین متغیرهای هواشناسی هستند که اثر زیادی بر کشاورزی دارند (10، 11 و 17).

1، 2، 3 و 4- به ترتیب دانشجوی کارشناسی ارشد آبخیزداری و استادیاران گروه مهندسی آبخیزداری، دانشکده کشاورزی، دانشگاه گنبد کاووس  
\* - نویسنده مسئول: (Email: S.m.seyedian@gmail.com)

جنوبی معتدل کوهستانی و در کوهپایه‌ها و قسمت‌های جنوبی جلگه‌ها معتدل مرطوب است، ولی در شمال گرگان‌رود به نیمه بیابانی و نیمه خشک تبدیل می‌شود در مجموع می‌توان هوای این شهر را معتدل و مرطوب عنوان کرد. میزان بارش سالانه حدود 500 میلی‌متر است. میزان بارندگی در این منطقه از جنوب به شمال و از شرق به غرب کاهش می‌یابد. میانگین سالانه دمای هوا در گنبدکاووس 18/6 درجه سانتی‌گراد است. میانگین حداکثر سالانه دمای هوا 24/5 و میانگین حداقل سالانه آن 12/7 درجه می‌باشد. میانگین دما در سردترین ماه یعنی ژوئن 8/1 درجه و در گرم‌ترین ماه یعنی اوت 29/9 درجه سانتی‌گراد می‌باشد. میانگین سالانه رطوبت نسبی هوا در گنبدکاووس 65 درصد می‌باشد. مرطوب‌ترین ماه، ژانویه با 75 درصد و خشک‌ترین ماه آن ژوئن با 54 درصد رطوبت نسبی است.

### داده‌های و اطلاعات مورد نیاز

در این پژوهش به منظور الگوسازی بارندگی ماهانه شهر گنبدکاووس با دو روش ANFIS و SVM از برخی پارامترهای هواشناسی ماهانه ایستگاه سینوپتیک گنبدکاووس و همچنین داده‌های بارندگی ماهانه ایستگاه‌های باران سنجی استان گلستان به عنوان متغیرهای ورودی استفاده شد. در این راستا دو ساختار براساس نیاز اطلاعاتی متفاوت طراحی شد:

ساختار اول: لایه ورودی شامل میانگین دما و رطوبت نسبی، فشار و سرعت باد در ایستگاه سینوپتیک گنبدکاووس.

ساختار دوم: در این ساختار ابتدا لایه ورودی شامل مقادیر ماهانه بارندگی ثبت شده در 22 ایستگاه باران سنجی استان گلستان می‌باشد که با اجرای آزمون پیرسون عوامل دارای ضریب همبستگی بالا برای اعمال در ورودی دو روش ANFIS و SVM استفاده شد. همچنین با توجه به نتایج همبستگی پیرسون، از آمار بارندگی ماهانه چهار ایستگاه آراز کوسه، بهلکه، تمر، آق‌قلا که همبستگی بیشتری با بارندگی ایستگاه گنبدکاووس داشتند استفاده گردید.

با توجه به سال تاسیس ایستگاه سینوپتیک گنبدکاووس طول دوره آماری مورد استفاده در این تحقیقات سال 1995 تا سال 2012 در نظر گرفته شده طوری که 80 درصد داده‌ها به منظور آموزش مدل‌ها و از 20 درصد مابقی داده‌ها به منظور صحت‌سنجی استفاده گردید. موقعیت شهرستان گنبدکاووس در کشور در شکل 1 نشان داده شده است.

### سیستم استنتاج فازی - عصبی تطبیقی

برای ایجاد ارتباط بین چند متغیر از روش‌های مختلفی می‌توان استفاده کرد. برخی از این روش‌ها عبارت‌اند از: رگرسیون خطی، شبکه‌های عصبی مصنوعی، سیستم‌های استنباط فازی و ترکیبی از شبکه‌های عصبی و سیستم‌های استنباط فازی که به سیستم‌های

مدل ANFIS<sup>1</sup> قابلیت خوبی در آموزش، ساخت و طبقه‌بندی دارد و همچنین دارای این مزیت است که اجازه استخراج قوانین فازی را از اطلاعات عددی یا دانش متخصص می‌دهد و به طور تطبیقی یک قاعده - بنیاد می‌سازد (2). فلاح قاهری و همکاران (6) بارش بهاره را با ANFIS در استان خراسان پیش‌بینی کردند. آن‌ها روش ضریب همبستگی پیرسون را به منظور تعیین موثرترین مشخصه‌های هواشناسی، به کار بردند. فلاح قاهری (5) به منظور پیش‌بینی بارش فصلی، سیگنال‌های هواشناسی موثر بر بارش استان خراسان را با روش همبستگی پیرسون تعیین کرد. سید نژاد گل خطمی (18) با استفاده از نظریه فازی و الگوریتم ژنتیک نشان دادند خطاهای منطقه‌ای بارش روزانه نسبت به روش‌های معمول به طور چشم‌گیری کاهش می‌یابد.

یکی دیگر از ابزارهای هوشمند که در سال‌های اخیر در زمینه‌های مختلف مورد استفاده قرار گرفته است ماشین بردار پشتیبان (SVM<sup>2</sup>) است. اخیراً این مدل‌ها در یک گستره وسیع از مسائل هیدرولوژیکی مورد استفاده قرار گرفته‌اند (16). یو و لینگ (22) از مدل SVM به منظور پیش‌بینی سری زمانی متغیرهای هیدرولوژیکی استفاده نمودند. دیبایک و همکاران (3)، SVM را در مدل‌سازی بارش - رواناب استفاده کردند. چن و همکاران (1) از SVM برای ریزمقیاس کردن بارش روزانه استفاده کردند و با روش آنالیز چندمتغیره مقایسه نمودند و نشان دادند نتایج پیش‌بینی‌های حاصل از SVM دقیق‌تر است. تریپانهی و همکاران (20)، از روش SVM برای برآورد بارندگی ماهانه در هند استفاده کردند. آن‌ها پیشنهاد کردند که SVM به عنوان گزینه برتر نسبت به سایر روش‌های معمول، برای پیش‌بینی بارش مورد استفاده قرار گیرد.

این مطالعه توانایی روش‌های هوش مصنوعی شامل ماشین بردار پشتیبان (SVM) و سامانه استنتاج فازی - عصبی (ANFIS) در الگوسازی بارش ماهانه مورد ارزیابی قرار گرفت. بارندگی به دو روش: 1- با اطلاعات هواشناسی و 2- با مقدار بارندگی ایستگاه‌های منطقه مورد مطالعه قرار گرفت.

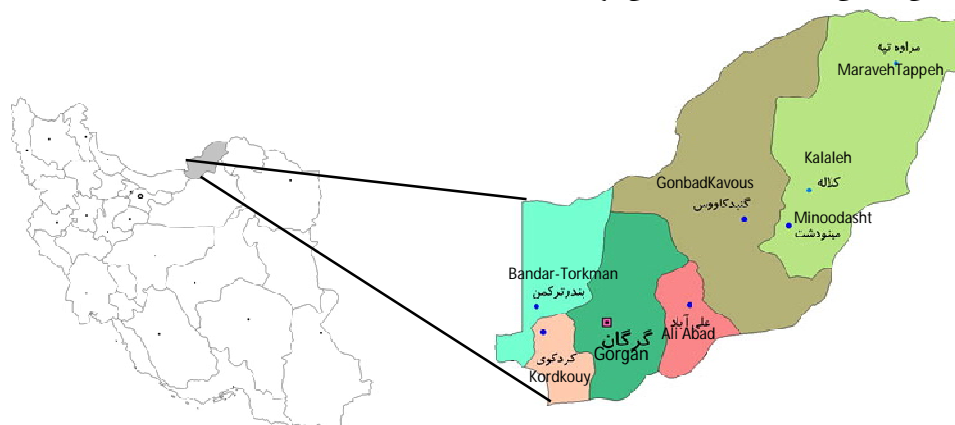
## مواد و روش‌ها

### منطقه مورد مطالعه

محدوده مورد مطالعه شهر گنبدکاووس در استان گلستان می‌باشد. این شهر در بخش شرقی استان گلستان در طول جغرافیایی "0° 10' 55" شرقی و عرض جغرافیایی "0° 15' 37" شمالی قرار دارد. گنبدکاووس از شمال به جمهوری ترکمنستان و از غرب به شهر گرگان محدود است. آب و هوای این شهر در ارتفاعات

1- Adaptive Neuro Fuzzy Inference System  
2- Support Vector Machine

فازی - عصبی تطبیقی یا ANFIS شناخته می‌شوند (12).



شکل 1- موقعیت شهرستان گنبدکاووس در ایران  
Figure 1- The city of Gonbad in Iran

نسبت هر قوه اشتعال  $\bar{I}$  آمین قانون، به مجموع همه قوه اشتعال قوانین می‌باشد. در نتیجه  $W$  به عنوان قوه اشتعال استاندارد شده به دست می‌آید.

$$O_{3,i} = \bar{W}_i = \frac{w_i}{w_1 + w_2} \quad (4)$$

لایه چهارم، گره‌های نتیجه: در این لایه خروجی هر گره برابر است با:

$$O_{4,i} = w_i f_i = w_i(p_i x + q_i y + r_i) \quad (5)$$

در این رابطه،  $w_i$  خروجی آمین گره از لایه قبلی است و  $\{p_i, q_i, r_i\}$  ضرایب این ترکیب خطی بوده، همچنین مجموعه پارامترهای بخش تالی مدل فازی تاکاگی - سوگنو نیز می‌باشند.

لایه پنجم، گره‌های خروجی: این لایه، تک گره خروجی کلی را با جمع کردن همه سیگنال‌های ورودی محاسبه می‌کند. بنابراین، در این لایه فرآیند غیرفعال‌سازی، نتایج هر قانون فازی را به خروجی غیرفازی تغییر شکل می‌دهد.

$$O_{5,i} = \frac{\sum_i w_i f_i}{\sum_i w_i} = \sum_i \bar{w}_i f_i \quad (6)$$

پارامترهای معرفی شده در این مدل در بالا معرفی شده‌اند.

این شبکه براساس یادگیری با نظارت آموزش داده می‌شود. بنابراین هدف، آموزش شبکه‌های فازی - عصبی تطبیقی است که قادر به تخمین توابع نامشخص حاصل از اطلاعات آموزش بوده و مقدار دقیقی برای پارامترهای مجهول پیدا کنند (شکل 2). ویژگی متمایز کننده ANFIS فراهم کردن الگوریتم یادگیری پیوندی، روش شیب گرادیان و روش حداقل مربعات، به منظور اصلاح پارامترها می‌باشد. روش شیب گرادیان پارامترهای غیرخطی مقدماتی  $(a_i, b_i)$  را تنظیم می‌کند، در حالی که روش مربعات خطا پارامترهای خطی بخش تالی را تعیین می‌نماید (15).

از زمانی که زاده تئوری منطق فازی را به منظور توصیف سیستم‌های پیچیده پیشنهاد نمود، این منطق به طور موفقیت‌آمیزی در مسائل مختلف به ویژه کنترل کننده‌هایی مثل راکتورهای شیمیایی، قطارهای خودکار و راکتورهای هسته‌ای به کار گرفته شده است (23). با وجود این، مشکل اصلی منطق فازی این است که روند سیستماتیک برای طراحی یک کنترل کننده فازی وجود ندارد اما یک شبکه عصبی این توانایی را دارد که از محیط آموزش ببیند (جفت‌های ورودی - خروجی)، ساختارش را خود مرتب کند و با شیوه‌ای تعامل خود را تطبیق دهد. بدین منظور، جنگ (13) مدل ANFIS را ارائه کرد که قابلیت ترکیب توانایی دو روش مذکور را داشت. ساختار ANFIS شامل پنج لایه می‌باشد:

لایه اول، گره‌های ورودی: هر گره از این لایه مقادیر عضویتی که به هر یک از مجموعه‌های فازی مناسب تعلق دارند، با استفاده از تابع عضویت تولید می‌کنند.

$$O_{1,i} = \mu_{A_i}(x) \quad \text{for } i=1,2 \quad (1)$$

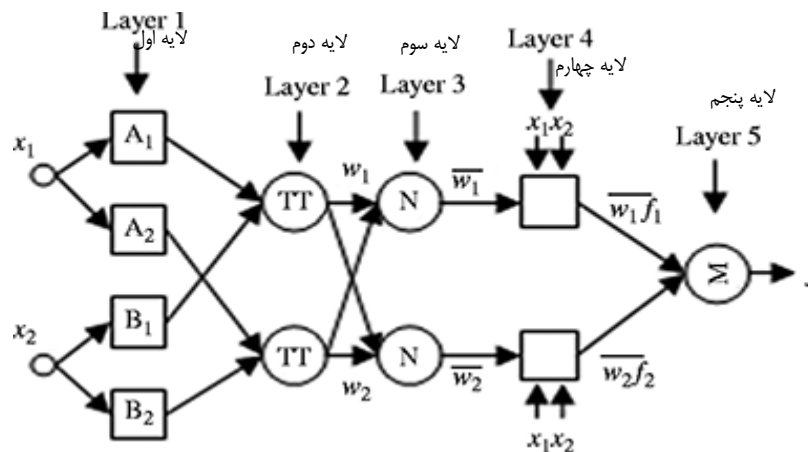
$$O_{1,i} = \mu_{B_{i-2}}(y) \quad \text{for } i=3,4 \quad (2)$$

$X$  و  $Y$  ورودی‌های غیرفازی به گره  $i$  و  $A_i$  و  $B_i$  برجسب‌های زبانی هستند که به ترتیب با توابع عضویت  $\mu_{A_i}$  و  $\mu_{B_i}$  مشخص می‌شوند این توابع با نماد  $O$  مشخص شده‌اند.

لایه دوم، گره‌های قاعده: هر نرون در این لایه ثابت است. در این لایه، عملگر "و" (AND) به کار برده می‌شود تا خروجی (قوه اشتعال) که نمایانگر بخش مقدم آن قانون است، به دست آید. خروجی‌های  $O_{2k}$  این لایه، حاصل ضرب درجات مربوط به لایه اول هستند که معادله آن به صورت زیر است:

$$O_{2,i} = w_i = \mu_{A_i}(x) \mu_{B_i}(y), \quad i=1,2 \quad (3)$$

لایه سوم، گره‌های متوسط: هدف اصلی در لایه سوم، تعیین



شکل 2- ساختار سیستم ANFIS با دو متغیر ورودی و دو قانون  
Figure 2- ANFIS system structure with two inputs and two rules

به دلیل کاربرد گسترده آن در مسائل رگرسیونی استفاده گردید. برای این مدل، تابع خطا به صورت زیر تعریف می‌شود:

$$C \sum_{i=1}^N \xi_i^2 w^T w + C \sum_{i=1}^N \xi_i \frac{1}{2} \quad (8)$$

تابع خطای مذکور لازم است که با توجه به محدودیت‌های زیر حداقل گردد.

$$\begin{aligned} & \phi^T(X_i) + b - y_i \leq \varepsilon + \xi_i^+ \\ & \varepsilon + \xi_i^+ y_i - w^T \phi(X_i) - b \leq \\ & \xi_i^+, \xi_i^- \geq 0, \quad i = 1, \dots, N \end{aligned} \quad (9)$$

که در این روابط C ثابت گنجایش، W بردار ضرایب،  $W^T$  ترانزپوز بردار ضرایب،  $\phi$  و  $\xi_i^+$  و  $\xi_i^-$  ضرایب کمبود، b ضریبی ثابت، N الگوی آموزش مدل و  $\phi$  تابع کرنل است. بنابراین در این تحقیق تابع مذکور که توسط  $\gamma$  در رابطه (8) تعریف شده است، به کار گرفته شد.

$$K(x_i, x) = \exp(-\gamma |x_i - x|^2) \quad (10)$$


باتوجه به روابط 8 تا 10 لازم است برای الگوسازی بارش توسط مدل SVM سه پارامتر  $\gamma$ ،  $\varepsilon$  و C بهینه شوند (21). شکل (3) ویژگی‌های یک ماشین بردار پشتیبان را نشان می‌دهد.

### ماشین بردار پشتیبان (SVM)

در یک مدل رگرسیونی SVM لازم است وابستگی تابع متغیر وابسته (y) به مجموعه‌ای از متغیرهای مستقل (x) تخمین زده شود. فرض بر این است که مانند دیگر مسائل رگرسیونی، رابطه بین متغیرهای وابسته و مستقل توسط یک تابع معین f به علاوه یک مقدار اضافی نویز مشخص می‌شود.

$$Y = f(x) + \text{noise} \quad (7)$$

بنابراین موضوع اصلی پیدا کردن فرم تابع f است که بتواند به صورت صحیح، موارد جدیدی را که SVM تاکنون تجربه نکرده است پیش‌بینی کند. این تابع به وسیله آموزش مدل SVM بر روی یک مجموعه داده به عنوان مجموعه آموزش که شامل فرآیندی به منظور بهینه‌سازی دائمی خطا است، قابل دسترسی می‌باشد. بر مبنای تعریف این تابع خطا، دو نمونه از مدل‌های SVM شناخته شده است که عبارتند از الف) مدل‌های رگرسیونی SVM نوع اول که به مدل‌های v-SVM مشهورند ب) مدل‌های رگرسیونی SVM نوع دوم که به مدل‌های  $\varepsilon$ -SVM مشهورند. در این مطالعه مدل  $\varepsilon$ -SVM



شکل 3- ساختار ماشین بردار پشتیبان  
Figure 3- SVM Structure

## آموزش مدل‌ها

$$MBE = \frac{\sum_{i=1}^n (y_{est_i} - y_{obs_i})}{n} \quad (13)$$

مقادیر مثبت و منفی MBE به ترتیب نشان می‌دهد مدل، بارش را بیشتر و کمتر از مقدار واقعی پیش‌بینی می‌کند. در این روابط،  $y_{obs}$  مقادیر مشاهده شده (واقعی)،  $\bar{y}_{obs}$  میانگین مقادیر مشاهده شده،  $y_{est}$  مقادیر برآورد شده (خروجی مدل)،  $\bar{y}_{est}$  میانگین مقادیر برآورد شده و  $n$  تعداد داده‌ها می‌باشد.

## نتایج و بحث

دینامیک و ساختار سری زمانی بارش بیان‌کننده تغییر بارش نسبت به زمان و تأثیر عوامل هواشناسی در تغییرات بارش است. در ساختار اولالگو سازی، پارامترهای مناسب از بین اطلاعات هواشناسی ایستگاه سینوپتیک گنبدانتخاب گردید و به‌عنوان داده‌های ورودی به مدل‌ها معرفی شدند. در ساختار دوم الگو سازی، از اطلاعات بارندگی ماهانه چهار ایستگاه باران سنجی استان گلستان با دوره آماری مناسب که همبستگی بیشتری با بارندگی ایستگاه گنبد کاووس داشتند به‌عنوان پارامتر ورودی و بارندگی گنبد کاووس به‌عنوان خروجی مدل‌های هوش مصنوعی استفاده شد.

جدول 1 وضعیت عملکرد آماری دو ساختار با دو روش هوش مصنوعی را نشان می‌دهد. نتایج آماری نشان می‌دهد در ساختار اول مقادیر ضریب تعیین برای هر دو مرحله آموزش و آزمون از کارایی تقریباً مناسبی در الگو سازی بارش شهر گنبد برخوردار نیست به طوری که مدل ANFIS و SVM در دوره آموزش به ترتیب با ضریب تعیین 0/67 و 0/33 و در مرحله آزمون به ترتیب دارای ضریب تعیین 0/45 و 0/40 هستند. همچنین مقادیر خطای RMSE نیز نشان می‌دهد هر دو مدل نتوانسته‌اند در ساختار اول بارندگی را پیش‌بینی نمایند.

نتایج حاصل از پیش‌بینی بارندگی با استفاده از بارندگی ایستگاه-های باران سنجی (ساختار دوم) در جدول 1 آورده شده است. ضریب تعیین مدل ANFIS در مرحله آموزش و آزمون به ترتیب 0/93 و 0/87 است و خطای RMSE نیز به ترتیب 7/06 و 9/28 می‌باشد. مقادیر MBE نشان می‌دهد ANFIS در مرحله آموزش کمتر و در مرحله آزمون بیشتر از مقدار واقعی پیش‌بینی کرده است. مقدار ضریب تعیین مدل SVM در مرحله آموزش و آزمون به ترتیب برابر 0/89 و 0/91 و خطای RMSE نیز به ترتیب برابر 9/28 و 5/59 است. مدل SVM بارندگی را در مرحله آموزش کمتر از مقدار واقعی و در مرحله آزمون بیشتر از مقدار واقعی پیش‌بینی می‌نماید.

مدل‌های ANFIS و SVM بارندگی را با استفاده از بارندگی ایستگاه‌های باران سنجی با دقت قابل قبولی الگو سازی می‌کنند. مقادیر ضریب تعیین در مرحله آموزش و آزمون اختلاف کمی با

برای الگو سازی بارش باید هر دو سیستم ANFIS و SVM را با یک سری داده‌های تاریخی یا اولیه آموزش داد و چون قوانین خاصی برای آموزش و طراحی شبکه‌های هوش مصنوعی موجود نیست، بنابراین با استفاده از فرآیند آزمون و خطا چندین ساختار را مورد آزمایش قرار داده و بهترین ساختار تعیین می‌گردد. در مدل ANFIS پس از بررسی 8 تابع عضویت مختلف (مثلثی، گوسی، ذوزنقه‌ای، زنگوله‌ای و ...) با 2 و 3 قانون برای هر ورودی و همچنین بررسی مقدار خروجی مدل (لایه چهارم) به صورت مقدار عددی و تابع خطی، بهترین ساختار برای هر سری از داده‌های ورودی تعیین گردید.

در مدل SVM نیز سه پارامتر  $C$ ،  $\gamma$  و  $\epsilon$  با استفاده از فرآیند آزمون و خطا بهینه و بهترین ساختار برای شبیه‌سازی فرآیند بارش تعیین گردید.

برای ارزیابی دقت مدل‌های عصبی- فازی تطبیقی و ماشین بردار پشتیبان از سه معیار آماری ضریب تعیین ( $R^2$ )، جذر میانگین مربعات خطا (RMSE) و میانگین خطای اریب (MBE) استفاده گردید که روابط آن به شرح زیر است:

$$\text{ضریب تعیین } (R^2)$$

ضریب همبستگی ( $R$ ) نشان‌دهنده میزان همبستگی بین مقادیر برآورد شده توسط مدل و مقادیر واقعی می‌باشد. این ضریب را می‌توان از رابطه (11) محاسبه کرد. مقدار ( $R^2$ ) ضریب تعیین نامیده می‌شود. مقدار این ضریب همواره بین صفر و یک قرار داشته و هر چه مقدار آن به 1 نزدیک‌تر باشد، نشان‌دهنده عملکرد بهتر مدل است.

$$R = \frac{\sum_{i=1}^n ((y_{obs})_i - (\bar{y}_{obs})) * ((y_{est})_i - (\bar{y}_{est}))}{\sqrt{\sum_{i=1}^n ((y_{obs})_i - (\bar{y}_{obs}))^2 \sum_{i=1}^n ((y_{est})_i - (\bar{y}_{est}))^2}} \quad (11)$$

جذر میانگین مربعات خطا<sup>3</sup> (RMSE)

یک شاخص کمی مناسب که می‌توان از آن در برآورد میزان دقت مدل استفاده کرد، مجذور میانگین مربعات خطا (RMSE) می‌باشد. این معیار، دقت مدل را براساس تفاضل بین مقادیر واقعی و مقادیر الگو سازی شده، ارزیابی می‌کند و هر چه به صفر نزدیک‌تر باشد، نمایانگر اختلاف کمتری بین آن‌ها خواهد بود. RMSE، به صورت رابطه (12) تعریف می‌شود:

$$RMSE = \sqrt{\frac{\sum_{i=1}^n (y_{est_i} - y_{obs_i})^2}{n}} \quad (12)$$

میانگین خطای اریب<sup>4</sup> (MBE)

- 1- Coefficient of Determination
- 2- Coefficient of Correlation
- 3- Error Root Mean Square of
- 4- Mean bias error

هواشناسی نشان می‌دهد الگوسازی بارندگی با توجه به عوامل منطقه‌ای دارای دقت کمی است و به عواملی خارج از منطقه مانند پارامترهای اقیانوسی-جوی بستگی دارد.

شکل‌های 4 و 5 مقادیر پیش‌بینی مدل‌ها با استفاده از پارامترهای هواشناسی را در مقابل مقادیر واقعی در مرحله آزمون نشان می‌دهند. پراکندگی نقاط در هر دو شکل زیاد است که نشان‌دهنده دقت کم مدل‌ها در الگوسازی است. پیش‌بینی مدل ANFIS برای مقادیر بارندگی کمتر از 20 میلی‌متر بیشتر از مقدار واقعی است اما برای مقادیر بیشتر از آن توزیع یکنواختی حول خط 1:1 دارد. مدل SVM در مرحله آزمون برای چند ماه مقدار بارندگی را منفی پیش‌بینی کرده است. مدل SVM برای مقادیر بیشتر از 90 میلی‌متر بارندگی کمتر از مقدار واقعی پیش‌بینی می‌کند که به دلیل تعداد کم این مقادیر در مرحله آموزش است که باعث می‌شود مدل برای این مقادیر به خوبی آموزش نبیند. به طور کلی توزیع نقاط حول خط 1:1 یکنواخت است.


یکدیگر دارند که نشان‌دهنده صحت نتایج مرحله آزمون است. ضریب تعیین در مرحله آزمون برای هر دو مدل تقریباً مشابه اما خطای RMSE در مدل SVM حدود 20 درصد کمتر از ANFIS است. هر دو مدل بارندگی را بیشتر از مقدار واقعی پیش‌بینی می‌کنند. مقادیر ضریب تعیین و خطا نشان می‌دهد دقت SVM بیشتر از ANFIS می‌باشد. فقیه (7) نیز با استفاده از بارندگی ایستگاه‌های مجاور، بارش ماهانه را با دقت بالایی پیش‌بینی کرد.

مدل‌های SVM و ANFIS با استفاده از بارندگی ایستگاه‌های باران سنجی شبیه‌سازی دقیق‌تری نسبت به پارامترهای هواشناسی انجام داده است. دقت هر دو مدل در الگوسازی بارندگی با استفاده از پارامترهای هواشناسی غیرقابل قبول است. اگرچه در مرحله آزمون ضریب تعیین ANFIS بیشتر است اما مقدار خطای آن بیشتر از SVM است. با توجه به قدرت بالای شبیه‌سازی مدل‌های هوش مصنوعی عدم تخمین دقیق بارندگی با استفاده از پارامترهای


جدول 1- نتایج حاصل از شبکه عصبی - فازی و ماشین بردار پشتیبان در ترکیب‌های مختلف ورودی

Table 1- The results of ANFIS and SVM in various combinations of input

پارامترهای ورودی Input parameters	مدل		R <sup>2</sup>	RMSE	MBE
ساختار اول دما، رطوبت، باد، فشار، بارش ایستگاه سینوپتیک گنبد Firs Structure Temperature, humidity, wind, pressure, Gonbad synoptic station	ANFIS	آموزش؛ Train	0.67	18.42	-0.0002
		آزمون؛ Test	0.45	23.15	3.60
ساختار دوم بارش ایستگاه‌های باران سنجی منتخب Second structure Rainfall selected stations	SVM	آموزش؛ Train	0.33	27.05	-5.56
		آزمون؛ Test	0.40	22.40	-2.24
	ANFIS	آموزش؛ Train	0.93	7.21	-4.98
		آزمون؛ Test	0.87	7.06	1.98
	SVM	آموزش؛ Train	0.89	9.28	-0.90
		آزمون؛ Test	0.91	5.59	0.49



شکل 5- نتایج آزمون شبکه فازی - عصبی در ترکیب‌ورودی دما، رطوبت، باد، فشار، بارش



شکل 4- نتایج آزمون ماشین بردار پشتیبان در ترکیب ورودی دما، رطوبت، باد، فشار، بارش


Figure 4- Results of support vector machine in combined of temperature, humidity, wind, pressure, precipitation

Figure 5- Results of ANFIS in combined of temperature, humidity, wind, pressure, precipitation

مرحله آزمون نشان می‌دهد تأثیر آن پارامتر از دیگر پارامترها بیشتر بوده است.

هنگامی که پارامترهای هواشناسی به عنوان ورودی مدل معرفی شدند کمترین مقدار ضریب تعیین و بیشترین مقدار خطا در مرحله آزمون با حذف پارامتر رطوبت به دست آمد. با حذف پارامتر رطوبت مقدار ضریب تعیین و خطای RMSE به ترتیب برابر 0/27 و 24/70 گردید. نکته قابل توجه این می‌باشد که با حذف هر یک از پارامترهای دما، فشار و سرعت باد مقدار ضریب تعیین و مقادیر خطا در مرحله آزمون تقریباً برابر گردید. آنالیز حساسیت نشان می‌دهد پارامتر رطوبت مهم‌ترین پارامتر و سه پارامتر دما، فشار و سرعت باد اهمیت یکسانی در الگوسازی بارندگی دارند. تحقیق ایلدرومی و همکاران (4) نیز نشان داد رطوبت نسبی بیشترین تأثیر را بر پیش‌بینی بارش سالانه دارد.

آنالیز حساسیت ایستگاه‌های باران سنجی در الگوسازی بارندگی نشان داد کمترین مقدار ضریب تعیین و بیشترین مقدار خطا در مرحله آزمون با حذف مقدار بارندگی ایستگاه ارازکوسه حاصل گردید. ایستگاه ارازکوسه بیشترین تأثیر در الگوسازی بارندگی و ایستگاه تمر با ضریب تعیین 0/87 و خطای RMSE برابر با 6/66 در رتبه دوم قرار دارد. دو ایستگاه بهلکه و آق‌قلا با مقادیر ضریب تعیین و خطای مشابه در رتبه سوم قرار داشته و کمترین تأثیر را بر الگوسازی بارندگی ایستگاه گنبد دارند.




شکل 7 - نتایج عصبی - فازی در ترکیب ورودی ایستگاه‌های باران سنجی

شکل‌های 6 و 7 الگوسازی بارندگی مدل‌های SVM و ANFIS را با استفاده از ایستگاه‌های باران سنجی نشان می‌دهند. پراکندگی نقاط حول خط 1:1 در مدل SVM تقریباً یکنواخت است اما در ANFIS تمرکز نقاط در بالای خط 1:1 اندکی بیشتر است که مقدار MBE (جدول 1) نیز این موضوع را نشان می‌دهد. به طور کلی در هر دو مدل پراکندگی نقاط مناسب است که نشان دهنده دقت خوب مدل‌ها در پیش‌بینی بارندگی است.

### تحلیل حساسیت

هدف از تحلیل حساسیت در این تحقیق شناسایی و تعیین درجه اهمیت هر یک از پارامترها در سری داده‌های ورودی بر عملکرد دینامیکی سیستم است. به منظور آنالیز حساسیت در هر سری داده ورودی یک پارامتر حذف و مدل با همان داده‌های سری آموزش و آزمایش مجدد اجرا و مقادیر ضریب تعیین و خطا تعیین گردید. با حذف هر پارامتر هر چه خطای مدل افزایش بیشتری نشان دهد بیانگر تأثیر بیشتر آن پارامتر بر فرآیند شبیه‌سازی می‌باشد.

جهت انجام تحلیل حساسیت برای هر دو سری داده‌های ورودی از روش SVM به دلیل دقیق‌تر بودن نتایج آن استفاده شد. در سری اول داده‌ها مهم‌ترین پارامتر هواشناسی از بین دما، رطوبت، سرعت باد و فشار و در سری دوم داده‌ها مهم‌ترین ایستگاه از بین ایستگاه‌های بهلکه، تمر، آق‌قلا و ارازکوسه تعیین شدند. جدول 2 مقادیر ضریب همبستگی و خطا را با حذف هر یک از پارامترهای ورودی نشان می‌دهد. با حذف هر پارامتر، مقدار بیشتر خطا و کمتر ضریب تعیین در



شکل 6 - نتایج ماشین بردار پشتیبان در ترکیب ورودی ایستگاه‌های باران سنجی

Figure 6- Results of support vector machine in combined of rainfall gauging station

Figure 7- Results of ANFIS in combined of rainfall gauging station

جدول 2- تحلیل حساسیت پارامترهای ورودی  
Table 2- Sensitivity analysis of input parameters

پارامترهای ورودی Input parameters	ورودی حذف شده Removed input		R <sup>2</sup>	RMSE	MBE
دما، رطوبت، سرعت باد، فشار Temperature, humidity, wind, pressure, Gonbad synoptic station	دما	آموزش؛ Train	0.32	27.15	-5.33
	Temperature	آزمون؛ Test	0.40	22.54	-2.41
	رطوبت	آموزش؛ Train	0.23	28.72	-5.29
	humidity	آزمون؛ Test	0.27	24.70	0.25
	فشار	آموزش؛ Train	0.33	26.96	-5.74
	pressure	آزمون؛ Test	0.40	22.43	-2.42
	سرعت باد	آموزش؛ Train	0.33	27.00	-5.49
	wind	آزمون؛ Test	0.40	22.40	-2.30
	بهبکه	آموزش؛ Train	0.89	9.62	-0.93
	Bahalke	آزمون؛ Test	0.90	5.94	0.85
بارش ایستگاه‌های بهبکه، تمر، آق‌قلا و آرازکوسه Rainfall of Bahalke, Tamar, AghGhala and Arazkoose station	تمر	آموزش؛ Train	0.88	9.83	-1.07
	Tamar	آزمون؛ Test	0.87	6.66	0.22
	آق‌قلا	آموزش؛ Train	0.89	9.60	-0.78
	AghGhala	آزمون؛ Test	0.90	5.97	0.93
	آرازکوسه	آموزش؛ Train	0.81	12.53	-1.60
	Arazkoose	آزمون؛ Test	0.78	9.21	0.69

## نتیجه‌گیری کلی

از داده‌های بارش ایستگاه‌های باران‌سنجی در الگوسازی بارندگی استفاده نمود. لازم به توضیح است با توجه به کمبود سال‌های آماری و عدم پوشش کامل قوانین ریاضی تدوین شده در مدل‌ها، انتظار می‌رود با افزایش سال‌های آماری دقت مدل در الگوسازی بارش افزایش یابد. مقایسه نتایج به‌دست آمده از این پژوهش نشان‌دهنده کارایی بالای روش ماشین بردار پشتیبان در شبیه‌سازی بارش است و می‌توان از این روش به‌طور موفقیت‌آمیزی در الگوسازی بارندگی استفاده کرد و در عمل کارایی مدل‌های الگوسازی بارش را افزایش داد. مهم‌ترین مزیت روش SVM نسبت به ANFIS سرعت بالای اجرای آن است. تعیین بهترین قوانین در ANFIS ممکن است چندین هفته به طول انجامد در صورتی که سرعت SVM چند برابر ANFIS است. به‌رحال، همواره باید توجه کرد که هرچند مدل‌های داده‌محور، نیازی به معادلات با پایه‌های فیزیکی (بیشتر به‌صورت غیرخطی و پیچیده‌اند) ندارند، ولی درک فرآیندها و تأثیر عوامل موردنظر در داده‌های ورودی بر روی خروجی مدل‌ها بسیار مهم است و در صورت عدم درک، نمی‌توان انتظار نتایج مطلوبی را داشت.

در این تحقیق توانایی دو روش ماشین بردار پشتیبان (SVM) و سیستم استنتاج فازی-عصبی (ANFIS) در الگوسازی ماهانه بارندگی مورد ارزیابی قرار گرفت. به‌منظور الگوسازی از دو سری داده شامل پارامترهای هواشناسی (دما، رطوبت، فشار و سرعت باد) و بارندگی متناظر ایستگاه‌های منطقه استفاده گردید. نتایج نشان داد شبیه‌سازی بارندگی با استفاده از پارامترهای هواشناسی توسط هر دو مدل دارای دقت کمی است. این موضوع نشان می‌دهد فرآیند بارندگی فقط به عوامل منطقه‌ای بستگی ندارد و تحت تأثیر پارامترهای فرامنطقه‌ای نیز است. پیش‌بینی بارندگی با استفاده از مقدار بارندگی ایستگاه‌های منطقه توسط هر دو مدل با دقت خوبی پیش‌بینی گردید. به‌طور کلی می‌توان گفت که در این مسئله نیز، مانند بسیاری از مسائل مهندسی، هوش مصنوعی موفق بوده است. نتایج نشان داد روش ماشین بردار پشتیبان به‌دلیل این که اساس آن بر پایه قوانین منطقی بیان شده است از دقت بالاتری نسبت به سیستم استنتاج فازی-عصبی برخوردار است.

در مجموع با توجه به نتایج به‌دست آمده از این تحقیق، می‌توان

## منابع

- 1- Chen S.T., Yu P.Sh., and Tang H.Y. 2010. Statistical downscaling of daily Precipitation using support vector machines and multivariate analysis. *Journal of Hydrology*, 385:13-23.
- 2- Dehghani A., Asghari M., and Mosaedi A. 2009. Comparison of three methods of artificial neural networks, adaptive



- neural fuzzy inference system and the number of interpolation groundwater level. *Journal of Agricultural Sciences and Natural Resources*, 16:517-529. (in Persian with English abstract)
- 3- Dibike Y.B., Velickov S., Solomatine D., and Abbott M.B. 2001. Model induction with support vector machines: introduction and applications. *Journal of Computing in Civil Engineering*, 15:208-216.
  - 4- Eilderomi A., ZareAbyaneh H., and Bayat M. 2012. Rainfall estimation using artificial neural network with meteorological data in three areas Ghyrbarshy Shiraz, Mashhad and Kerman. *Journal of Geography and Planning*, 43:21-40. (in Persian with English abstract)
  - 5- Faghieh H. 2010. Evaluating and optimizing the use of artificial neural network with genetic algorithm estimates the monthly precipitation data (Case study: The Kurdistan Region). *Science and Technology of Agriculture and Natural Resources, Water and Soil Sciences*, 14:27-42. (in Persian with English abstract)
  - 6- FallahGhaheeri Gh., HabibiNokhandan M., and Khoshhal J. 2010. Khorasan spring rainfall prediction based fuzzy inference system using remote link synoptic patterns of neural adaptation (ANFIS). *Journal of Range and Watershed Management, Journal of Natural Resources*, 1:55-74. (in Persian with English abstract)
  - 7- FallahGhaheeri Gh., MousaviBayki M., and HabibiNokhandan M. 2008. Khorasan spring rainfall prediction based fuzzy inference system using remote link synoptic patterns of neural adaptation (ANFIS). *Physical Geography Research*, 66:121-129.(in Persian)
  - 8- FathAbadi A., Salajeghe A., and Mahdavi M. 2008. River flow forecasting using Neuro Fuzzy and time series models. *Iran Watershed Science and Engineering*, 2:21-30. (in Persian with English abstract)
  - 9- FeyziV., and Farajzadeh M. 2010. Study climate change in the province Kendall method. *Proceedings of the Fourth International Congress of the Humanities, Zahedan*, p. 2-12.(in Persian)
  - 10- Geng S., Penning-de-vries F.W.T., and Supit I. 1986. A simple method for generating daily rainfall data. *Agricultural and Forest Meteorology*, 36:363-376.
  - 11- Hoogenboom G. 2000. Contribution of agrometeorology to the simulation of crop production and its applications. *Agricultural and Forest Meteorology*, 103:137-157.
  - 12- JacquinaA.p., and Shamseldin A.Y. 2006. Development of rainfall- runoff models using takagi- sugeno fuzzy Inference System. *Journal of Hydrology*, 329:154-173.
  - 13- Jang J.S.R. 1993. ANFIS: adaptive- network- based fuzzy inference systems. *IEEE Transactions on Systems, Man and Cybernetics*, 23:665-685.
  - 14- Matreata M. 2006. Artificial neural network and fuzzy logic models in operational hydrological forecasting system, *Geophysical Research Abstracts*, 8:43-51.
  - 15- Nabizadeh M., Mosaedi A., and Dehghani A. 2012. Estimate adaptive neural fuzzy inference system using smart daily rate. *Journal of irrigation and water management*, 1:69-80. (in Persian with English abstract)
  - 16- Nouri R., Khakpour A., Dehghani A., and Farokhnia A. 2010. Monthly forecast streamflow using support vector machine based on principal component analysis. *Water and Wastewater*, 1:118-123. (in Persian with English abstract)
  - 17- Sentelhas P.C., de Faria R.T., Chaves M.O., and Hoogenboom G. 2001. Evaluation of the WGEN and SIMMETEO weather generators for the Brazilian tropics and subtropics, using crop simulation models. *Revista Brasileira de Agrometeorologia, Santa Maria*, 9:357-376.
  - 18- SeyedNejadGolkhatmi N., SanayiNejad S., Ghahreman B., and RezaeiPajand H. 2014. Engineering equations, fuzzy theory and genetic algorithms optimization of daily rainfall in the catchment area of Mashhad plain. *Journal of Soil and Water (Agricultural Science and Technology)*, 28:1-9. (in Persian with English abstract)
  - 19- TokarA.S., and Santon P.A. 1999. Rainfall- Runoff modeling using artificial neural networks. *Journal of Hydrologic Engineering*, 3:232-233.
  - 20- Tripathi Sh., Srinivas V.V., and Nanjundiah R.S. 2006. Downscaling of precipitation for climate change scenarios: A support vector machine approach. *Journal of Hydrology*, 330:62- 640.
  - 21- Vapnik V.N. 1998. *Statistical learning theory*. 1st Ed., Wiley, New York.
  - 22- Yu X., and Liang S.Y. 2006. Forecasting of hydrologic time series with ridge regression in feature space. *Journal of Hydrology*, 332:290-302.
  - 23- Zadeh L.A. 1965. Quantative fuzzy sets. *Information and Control*. 8:338-353.

## SVM and ANFIS Models for precipitation Modeling (Case Study: GonbadKavouse)

N. Zabet Pishkhani<sup>1</sup>- S.M. Seyedian<sup>\* 2</sup>- A. Heshmat Pour<sup>3</sup>- H. Rouhani<sup>4</sup>

Received: 16-07-2014

Accepted: 16-03-2015

**Introduction:** In recent years, according to the intelligent models increased as new techniques and tools in hydrological processes such as precipitation forecasting. ANFIS model has good ability in train, construction and classification, and also has the advantage that allows the extraction of fuzzy rules from numerical information or knowledge. Another intelligent technique in recent years has been used in various areas is support vector machine (SVM). In this paper the ability of artificial intelligence methods including support vector machine (SVM) and adaptive neuro fuzzy inference system (ANFIS) were analyzed in monthly precipitation prediction.

**Materials and Methods:** The study area was the city of Gonbad in Golestan Province. The city has a temperate climate in the southern highlands and southern plains, mountains and temperate humid, semi-arid and semi-arid in the north of Gorganroud river. In total, the city's climate is temperate and humid. In the present study, monthly precipitation was modeled in Gonbad using ANFIS and SVM and two different database structures were designed. The first structure: input layer consisted of mean temperature, relative humidity, pressure and wind speed at Gonbad station. The second structure: According to Pearson coefficient, the monthly precipitation data were used from four stations: Arazkoose, Bahalke, Tamar and Aqqala which had a higher correlation with Gonbad station precipitation. In this study precipitation data was used from 1995 to 2012. 80% data were used for model training and the remaining 20% of data for validation. SVM was developed from support vector machines in the 1990s by Vapnik. SVM has been widely recognized as a powerful tool to deal with function fitting problems. An Adaptive Neuro-Fuzzy Inference System (ANFIS) refers, in general, to an adaptive network which performs the function of a fuzzy inference system. The most commonly used fuzzy system in ANFIS architectures is the Sugeno model since it is less computationally exhaustive and more transparent than other models. A consequent membership function (MF) of the Sugeno model could be any arbitrary parameterized function of the crisp inputs, most like lya polynomial. Zero and first order polynomials were used as consequent MF in constant and linear Sugeno models, respectively. In addition, the defuzzification process in Sugeno fuzzy models is a simple weighted average calculation. The fuzzy space was divided via grid partitioning according to the number of antecedent MF, and each fuzzy region was covered with a fuzzy rule.

**Results Discussion:** The statistical results showed that in first structure determination coefficient values for both the training and test was not good performance in precipitation prediction so that ANFIS and SVM had determination coefficient of 0.67 and 0.33 in training phase and 0.45 and 0.40 in test phase. Also the error RMSE values showed that both models had failed to predict precipitation in first structure. The results of second structure in precipitation prediction showed that determination coefficient of ANFIS at training and testing was 0.93 and 0.87 respectively and RMSE was 7.06 and 9.28 respectively. MBE values showed that the ANFIS underestimated at training phase and overestimated at test phase. Determination coefficient of SVM at training and testing was 0.89 and 0.91 respectively and RMSE was 9.28 and 5.59 respectively. SVM underestimated precipitation at train phase and overestimated it at test phase. ANFIS and SVM modeled precipitation using precipitation gauging stations with reasonable accuracy. Determining coefficient in the test phase was almost the same for ANFIS and SVM but the RMSE error of SVM model was about 20% lower than the ANFIS. The coefficient of determination and error values indicated SVM had greater accuracy than ANFIS. ANFIS overestimated precipitation for less than 20 mm but for higher values of uniformly distributed around the 1:1. SVM underestimated precipitation for more than 90 mm precipitation due to the low number of data in the training phase, which made this model, did not train well. When meteorological parameters were introduced as input, minimum determination coefficient and maximum error in the test phase occurred while humidity parameters were removed. By removing any of the parameters of temperature, pressure and wind speed the error values and coefficient of determination in test phase was approximately equal.

1, 2, 3 and 4- M.Sc Graduated of Watershed Management and Assistants Professor of Watershed Management, Faculty of Agriculture and Natural Resources, University of GonbadKavous, GonbadKavous, Respectively

(\*-Corresponding Author Email: S.m.seyedian@gmail.com)

**Conclusion:** The potential of the support vector machine (SVM) and neuro fuzzy inference system (ANFIS) in monthly precipitation pattern were analyzed. In order to model, two data sets were used containing meteorological parameters (temperature, humidity, pressure and wind speed) and the stations precipitation. The results showed that the simulated precipitation using meteorological parameters by ANFIS and SVM had low accuracy. Precipitation forecasting using stations precipitation in the region had good accuracy by ANFIS and SVM. Comparing the results of this study showed the high efficiency of SVM in simulating precipitation. This method can be successfully used in modeling precipitation to increase efficiency of precipitation modelling.

**Keywords:** ANFIS, Modeling, Monthly precipitation , Support Vector Machine