



ارزیابی راهبرد ترکیب مدل‌ها در افزایش دقت پیش‌بینی بارش پاییزه

فرشته مدرسی^۱، شهاب عراقی نژاد^{۲*}، کیومرث ابراهیمی^۲

تاریخ دریافت: ۱۳۹۴/۰۳/۲۷

تاریخ پذیرش: ۱۳۹۴/۱۰/۲۰

چکیده

پیش‌بینی بارش پاییزه در برنامه‌ریزی‌های کشاورزی به ویژه امکان سنجی کشت دیم از اهمیت ویژه‌ای برخوردار است. در مطالعه حاضر، برای افزایش دقت پیش‌بینی بارش پاییزه از تکنیک ترکیب مدل‌ها استفاده شده است. به این منظور، بر اساس دو شاخص اقلیمی SOI و NINO 3.4 به عنوان متغیرهای پیش‌بینی کننده، پنج مدل شبکه عصبی مصنوعی، شبکه عصبی رگرسیون تعمیم یافته، رگرسیون بردار پشتیبان، K نزدیک‌ترین همسایگی و رگرسیون خطی با ساختار بهینه به عنوان مدل‌های منفرد پیش‌بینی کننده بارش اجرا شده‌اند. برای ترکیب مدل‌های مذکور از راهبرد وزن‌دهی رتبه‌بندی شده به مدل‌ها (OWA) استفاده شده که در آن، برای تعیین وزن مدل‌ها، دو روش Orlike و Omess مورد استفاده و ارزیابی قرار گرفتند. نتایج پیش‌بینی بارش در زیرحوضه سیمره از حوضه کرخه نشان می‌دهد که بارش پیش‌بینی شده با استفاده از راهبرد ترکیب مدل‌ها از دقت بیشتری نسبت به مدل‌های منفرد برخوردار است و روش Orlike در مقایسه با روش Omess، دقت پیش‌بینی‌ها را بیشتر افزایش می‌دهد. همچنین، مقایسه نتایج روش‌های راهبرد OWA با دو راهبرد ترکیب مدل‌ها با شبکه عصبی مصنوعی و راهبرد انتخاب بهترین مدل منفرد نشان می‌دهد که قابلیت هر دو روش Omess و Orlike برای بهبود دقت پیش‌بینی بارش، بیش از راهبردهای شبکه عصبی و بهترین مدل منفرد است.

واژه‌های کلیدی: ترکیب مدل‌ها، وزن‌دهی رتبه‌بندی شده، Omess، Orlike، SOI، NINO 3.4

مقدمه

گرفته شده است. پدیده انسو بر مناطق مختلف کره زمین تأثیر متفاوتی نظیر خشکسالی‌های شدید و بارش‌های سیل‌آسا می‌گذارد. آلن و همکاران^۴ (۱۹۹۶) و کریپالانی و کولکارانی^۵ (۱۹۹۷) تأکید کرده‌اند که انسو از مهم‌ترین پدیده‌های شناخته شده و ناشی از واکنش‌های متقابل اقیانوس-جو و خشکی است و سبب تغییرات اقلیمی در مقیاس سالانه در سطح کره زمین می‌شود. مطالعات صورت گرفته نشان می‌دهد که پدیده انسو بر بارش مناطق مختلف جهان نظیر آفریقا (روپلوسکی و هالپرت^۶، ۱۹۸۹)، غرب آمریکا (ردموند و کچ^۷، ۱۹۹۱)، استرالیا (چیو و همکاران^۸، ۱۹۹۸)، شرق آسیا (رنگونج و سوهوا^۹، ۲۰۰۰) و غرب اروپا

پیش‌بینی بلندمدت بارش، در برنامه‌ریزی‌های منابع آب بالاخص تخصیص آب به بخش کشاورزی و تعیین نوع الگوی کشت از اهمیت ویژه‌ای برخوردار است. با توجه به انجام کشت دیم در فصل پاییز، پیش‌بینی بارش پاییزه علاوه بر اثرگذاری بر کشت آبی، در تعیین نوع الگوی کشت دیم نیز اثرگذار است. از این‌رو، افزایش دقت پیش‌بینی بارش در این فصل ضروری است. یکی از مهم‌ترین منابع اثرگذار بر تغییرات جوی و اقلیمی در مناطق مختلف جهان و به‌خصوص در مناطق حاره‌ای، پدیده انسو (ENSO) است. انسو از دو واژه النینو (El Nino) و نوسانات جنوبی (SOI)

^۴ Allen et al.

^۵ Kripalani and Kulkarani

^۶ Ropelewski and Halpert

^۷ Redmond and Koch

^۸ Chiew et al.

^۹ Renguang and Xiouhua

^۱ دانشجوی دکتری مهندسی منابع آب، گروه مهندسی آبیاری و آبادانی،

دانشگاه تهران

^۲ دانشیار گروه مهندسی آبیاری و آبادانی، دانشگاه تهران

(*نویسنده مسئول: araghinejad@ut.ac.ir)

³ South Oscillation Index (SOI)

هر یک از مدل‌های مذکور در مدل‌سازی با خطاهایی همراه هستند که غیرقابل اجتناب است و منجر به کاهش دقت نتایج می‌شود. از سال ۲۰۰۰ تکنیک ترکیب مدل‌ها برای افزایش دقت پیش‌بینی‌های کوتاه‌مدت و بلندمدت زمانی، مکانی و زمانی- مکانی در علوم مربوط به منابع طبیعی و محیط زیست نظیر پیش‌بینی پدیده مه (میتسوکورا و همکاران^۷، ۲۰۰۲)، پیش‌بینی زمانی رطوبت خاک (خلیلی و همکاران، ۲۰۰۵)، پیش‌بینی کوتاه‌مدت و بلندمدت دینامیکی اقیانوس‌ها (لسلی و همکاران^۸، ۲۰۰۸) و پیش‌بینی سرعت و پروفیل باد (مندبک و همکاران^۹، ۲۰۰۹) به کار برده شده است. تکنیک ترکیب مدل‌ها زیرمجموعه‌ای از تکنیک ترکیب اطلاعات می‌باشد به گونه‌ای که نتیجه حاصل از آمیختن داده‌های به‌دست آمده از منابع مختلف، جامع‌تر، دقیق‌تر و مطمئن‌تر از نتایج حاصل از هر یک از منابع اولیه باشد (هال و لیناس^{۱۰}، ۱۹۹۷). ترکیب مدل‌ها در قالب دیدگاه‌های موازی، سری و ترکیب آن‌ها صورت می‌گیرد (داساراتی^{۱۱}، ۱۹۹۴). در دیدگاه ترکیب موازی مدل‌ها، نتایج حاصل از چندین مدل منفرد با روش‌هایی نظیر وزدن دهی و خودراه‌اندازی^{۱۲} با یکدیگر ترکیب می‌شوند تا نتایج دقیق‌تری حاصل شود؛ در حالیکه در دیدگاه ترکیب سری مدل‌ها، نتایج حاصل از یک مدل به عنوان ورودی به مدل دیگر وارد می‌شود و در دیدگاه ترکیبی نتایج حاصل از چندین مدل منفرد به عنوان ورودی به یک مدل دیگر وارد می‌شود. در زمینه پیش‌بینی‌های کوتاه‌مدت و بلندمدت هیدرولوژیک نیز تکنیک ترکیب مدل‌ها در قالب روش‌هایی نظیر میانگین‌گیری ساده و وزنی (دیدگاه موازی) (سی و آبراهارت^{۱۳}، ۲۰۰۱؛ گوسوامی و اوکانر^{۱۴}، ۲۰۰۷؛ عزمی و همکاران، ۲۰۱۰)، و روش‌های فازی و شبکه عصبی (دیدگاه ترکیبی) (ژانگ و همکاران^{۱۵}، ۲۰۰۱؛ آبراهارت و سی^{۱۶}،

(ماریوتی و همکاران^۱، ۲۰۰۲) اثرگذار است. در ایران نیز تحقیقاتی در این زمینه صورت گرفته است، از آن جمله، عزیزی (۱۳۷۹) رابطه نینو را با دوره‌های ترسالی و خشکسالی در ایران بررسی نمود و نشان داد که ارتباط نسبتاً قوی بین بارش سالانه ایران و شاخص نوسانات جنوبی (SOI) وجود دارد. ناظم‌السادات و کوردری^۲ (۲۰۰۰) اثر پدیده انسو را بر بارش پاییزه ایران مورد بررسی قرار دادند. نتایج تحقیقات آن‌ها نشان داد که شاخص نوسانات جنوبی (SOI) دارای همبستگی منفی با بارش پاییزه می‌باشد و متوسط تابستانه این شاخص، پیش‌بینی کننده مناسبی برای بارش پاییزه است. همچنین، پدیده انسو اثر قابل توجهی بر بارش پاییزه دامنه جنوبی البرز و استان‌های شمال‌غرب ایران می‌گذارد. در تحقیق دیگری، کوره‌پزان دزفولی (۱۳۸۲) با بررسی شاخص‌های بزرگ‌مقیاس اقلیمی برای پیش‌بینی بارش مناطق جنوبی ایران نشان داد که شاخص نوسانات جنوبی (SOI) پیش‌بینی کننده مناسبی برای بارش پاییزه در این مناطق می‌باشد. فتاحی و همکاران (۱۳۸۷) با بررسی اثر سیگنال‌های بزرگ‌مقیاس اقلیمی بر بارش‌های کوتاه‌مدت و بلندمدت در ناحیه جنوب غرب ایران نشان دادند که پدیده انسو در نواحی نینو ۱+۲ (NINO 1+2)، نینو ۳ (NINO 3) و نینو ۳/۴ (NINO 3.4) مؤثرترین سیگنال‌ها برای پیش‌بینی بارش در ناحیه جنوب غرب ایران هستند. فتاحی مرج و مهدیان (۱۳۸۸) نیز نشان دادند که شاخص نوسانات جنوبی (SOI) و شاخص نینو ۳/۴ (NINO 3.4) مؤثرترین پیش‌بینی کننده‌ها برای پیش‌بینی بارش پاییزه در حوضه دریاچه ارومیه هستند. برای انجام پیش‌بینی‌های بلندمدت هواشناسی و هیدرولوژیک، در اکثر تحقیقات صورت گرفته از روش‌هایی نظیر شبکه‌های عصبی (وو و همکاران^۳، ۲۰۱۰؛ چن و همکاران^۴، ۲۰۱۴)، ماشین بردار پشتیبان (کیسی و سیمن^۵، ۲۰۱۲؛ سو و همکاران^۶، ۲۰۱۴) و K نزدیک‌ترین همسایگی (عراقی نژاد و همکاران، ۲۰۰۶؛ میدانی و عراقی نژاد، ۲۰۱۴) استفاده شده است. از آنجا که

⁷ Mitsukura et al.

⁸ Leslie et al.

⁹ Mandic et al.

¹⁰ Hall and Linas

¹¹ Dasarathy

¹² Bootstrap

¹³ See and Abrahart

¹⁴ Goswami and O'Connor

¹⁵ Xiong et al.

¹⁶ Abrahart and See

¹ Mariotti et al.

² Cordery

³ Wu et al.

⁴ Chen et al.

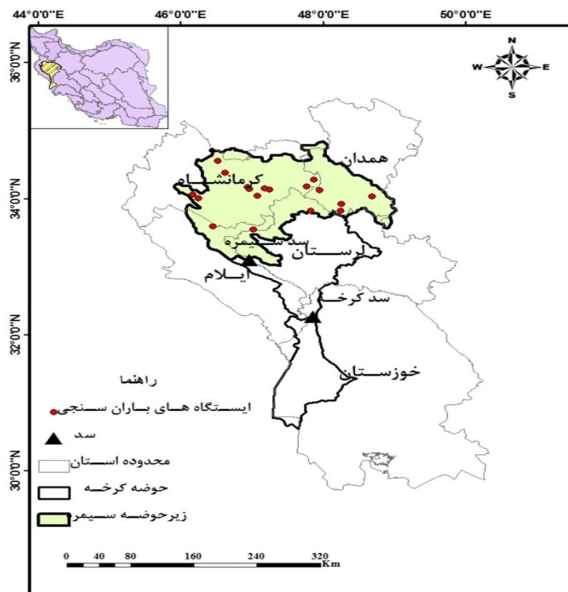
⁵ Kisi and Cimen

⁶ Su et al.

مواد و روش‌ها

منطقه مطالعاتی و داده‌های مورد استفاده

زیرحوضه سیمره در بالادست سد سیمره قرار دارد و مساحت تقریبی آن ۱۸۹۶۰ کیلومتر مربع است. موقعیت این زیرحوضه در حوضه کرخه در شکل ۱ نشان داده شده است.



شکل ۱- موقعیت زیرحوضه سیمره و ایستگاه‌های باران‌سنجی آن

برای انجام تحقیق حاضر از اطلاعات بارش ماهانه ۱۸ ایستگاه باران‌سنجی متعلق به وزارت نیرو در بازه زمانی ۱۳۹۲-۱۳۶۱ استفاده و متوسط بارش پاییزه ۱۸ ایستگاه محاسبه شده است. موقعیت ایستگاه‌های باران‌سنجی در شکل ۱ نشان داده شده است. همچنین، بر اساس تحقیقات صورت گرفته در ایران برای پیش‌بینی بارش پاییزه (ناظم‌السادات و کوردی، ۲۰۰۰؛ کوره‌پزان دزفولی، ۱۳۸۲؛ فتاحی و همکاران، ۱۳۸۷؛ فاتحی مرج و مهدیان، ۱۳۸۸) متوسط تابستانه دو شاخص نوسانات جنوبی (SOI) و NINO3.4 به عنوان متغیرهای پیش‌بینی کننده بارش پاییزه مناسب شناخته شده است. شاخص نوسانات جنوبی (SOI) نشان‌دهنده اختلاف فشار سطح آب اقیانوس آرام بین تاهیتی در شرق و داروین استرالیا در غرب اقیانوس آرام می‌باشد و شاخص NINO3.4 نشان‌دهنده دمای متوسط سطح آب دریا در شرق مرکز اقیانوس آرام حراره‌ای در موقعیت ۵S-۵N و ۱۲۰W-۱۷۰W است که از میان

۲۰۰۲؛ شمس‌الدین و همکاران، ۲۰۰۷) سبب ارتقاء دقت نتایج پیش‌بینی شده است. مقایسه روش‌های مذکور در مطالعات صورت گرفته نشان می‌دهد که روش شبکه عصبی در ارتقاء دقت نتایج، بر سایرین برتری داشته است. مدرسی و همکاران (۱۳۹۴) از استراتژی وزن‌دهی رتبه‌بندی شده^۱ (OWA) بر مبنای روش Orness برای ترکیب مدل‌های پیش‌بینی کننده جریان ماهانه استفاده نمودند و نشان دادند که روش پیشنهادی آن‌ها، دقت نتایج را به ترتیب نسبت به استراتژی ترکیب مدل‌ها با شبکه عصبی و نیز استراتژی انتخاب بهترین مدل منفرد به طور متوسط ۵۵ و ۴۶ درصد افزایش داده است. روش وزن‌دهی رتبه‌بندی شده (OWA) اولین بار توسط یاگر^۲ در سال ۱۹۸۸ ارائه شده است که در آن دامنه وسیعی از وزن‌ها به صورت مستقل از عوامل وزن گیرنده ایجاد می‌شود و با توجه به اهمیت عوامل مختلف، هر وزن می‌تواند به مورد خاصی اختصاص یابد. به این دلیل، کاربرد اصلی این روش در تحقیقات صورت گرفته، در زمینه فرآیندهای تصمیم‌گیری^۳ بوده است (ماکروپولوس و باتلر^۴، ۲۰۰۶؛ چیکلانا و همکاران^۵، ۲۰۰۷؛ ژو و چن^۶، ۲۰۱۱). با توجه به آنچه بیان شد، در مقاله حاضر، برای افزایش دقت پیش‌بینی بارش پاییزه در زیرحوضه سیمره از حوضه کرخه، در گام نخست، اثر دو شاخص اقلیمی SOI و NINO 3.4 به عنوان متغیرهای پیش‌بینی کننده بر اساس نتایج پنج مدل منفرد ارزیابی و بهترین شاخص پیش‌بینی کننده بارش پاییزه تعیین شده است. سپس، در گام دوم، بر مبنای نتایج پیش‌بینی حاصل از بهترین شاخص اقلیمی پیش‌بینی کننده، از روش ترکیب مدل‌ها بر مبنای استراتژی وزن‌دهی رتبه‌بندی شده (OWA) برای افزایش دقت پیش‌بینی‌های صورت گرفته استفاده شده است. در این راستا، کارایی دو روش Orness و Orlike برای تعیین وزن مدل‌های منفرد مقایسه شده و نسبت به استراتژی‌های ترکیب مدل‌ها با شبکه عصبی و نیز انتخاب بهترین مدل منفرد مورد ارزیابی قرار گرفته است.

¹ Ordered Weighted Aggregation

² Yager


³ Decision Making

⁴ Makropoulos and Butler

⁵ Chiclana et al.

⁶ Zhou and Chen

نرمال استاندارد شاخص‌های اقلیمی و بارش پاییزه استفاده شده است. شایان ذکر است که در مقاله حاضر از داده‌های شاخص‌های اقلیمی در بازه زمانی ۲۰۱۳-۱۹۸۲ (منطبق بر دوره زمانی ۱۳۹۲-۱۳۶۱) استفاده شده که این داده‌ها در بازه زمانی ماهانه در سایت مرکز ملی پیش‌بینی‌های محیط زیست (NCEP) در دسترس می‌باشد. با توجه به شکل ۲ نیز مشاهده می‌شود که بارش متوسط پاییزه در منطقه مطالعاتی دارای همبستگی منفی با شاخص SOI با ضریب زاویه $-0/54$ و دارای همبستگی مثبت با شاخص NINO 3.4 با ضریب زاویه $0/423$ است.



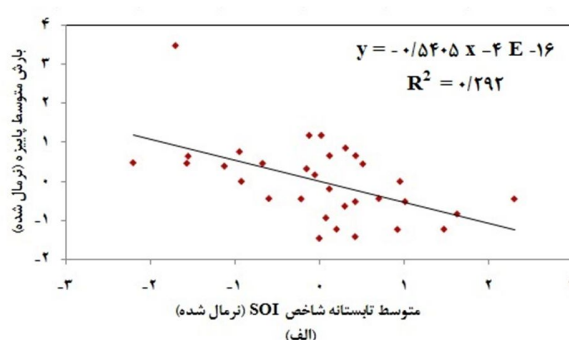
شکل ۲- تغییرات بارش متوسط پاییزه زیرحوضه سیمره با متوسط تابستانه شاخص SOI (الف) و شاخص NINO 3.4 (ب)

نام پارامترهای بهینه شده برای هر مدل آورده شده است. برای مطالعه بیشتر در مورد جزئیات ساختار مدل‌های منفرد به عراقی‌نژاد (۲۰۱۴) مراجعه شود.

۲- انتخاب بهترین نتایج مدل‌های منفرد بر اساس نوع متغیر پیش‌بینی کننده

در این مرحله، نتایج حاصل از مدل‌های منفرد که از به‌کارگیری متغیرهای پیش‌بینی کننده متفاوت ایجاد شده‌اند بر اساس سه معیار نش-ساتکلیف^۱، ریشه متوسط مربعات خطا (RMSE) و ضریب تبیین (R^2) میان مقادیر بارش مشاهداتی و مدل‌سازی شده ارزیابی و بهترین نتیجه مدل‌های منفرد (حاصل از بهترین متغیر پیش‌بینی کننده) برای مرحله ترکیب مدل‌ها انتخاب شده است.

شاخص‌های NINO، نزدیک‌ترین موقعیت را نسبت به ایران دارد. بررسی‌های صورت گرفته بر روی میزان همبستگی بارش متوسط پاییزه در منطقه مطالعاتی و متوسط فصلی شاخص‌های SOI و NINO 3.4 نیز نشان می‌دهد که بیش‌ترین همبستگی میان متوسط تابستانه این دو شاخص با بارش پاییزه وجود دارد؛ به طوری که مقدار ضریب تبیین (R^2) میان بارش متوسط پاییزه و متوسط تابستانه شاخص‌های SOI و NINO 3.4 به ترتیب برابر با $-0/54$ و $0/423$ است. در شکل ۲ (الف و ب) به ترتیب چگونگی همبستگی متوسط تابستانه شاخص‌های SOI و NINO 3.4 با بارش پاییزه نشان داده شده است. در این شکل، از مقادیر

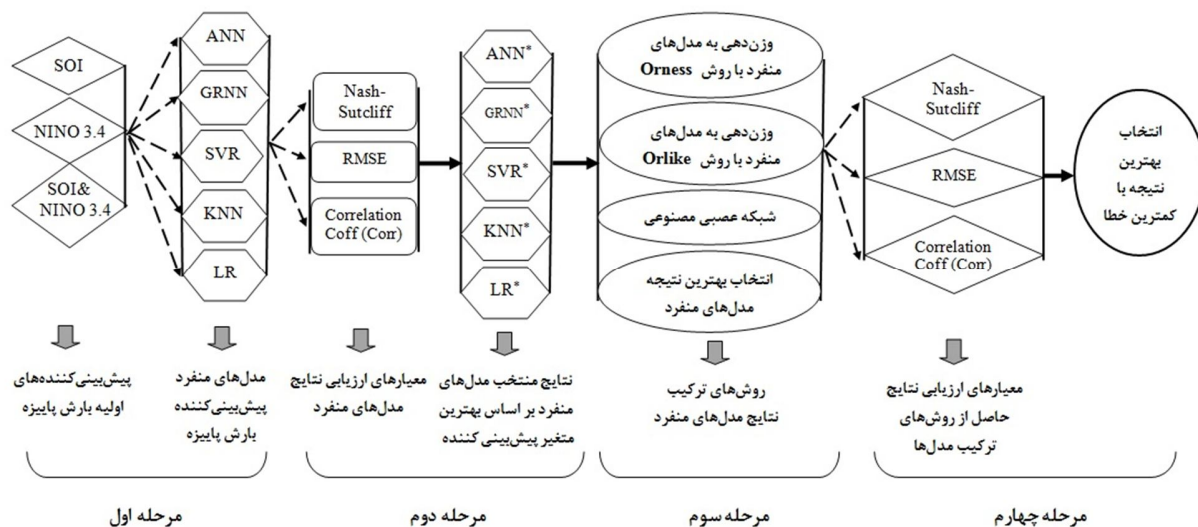


روش انجام تحقیق

تحقیق حاضر در یک الگوریتم چهارمرحله‌ای مطابق شکل ۳ انجام شده است که شرح آن به صورت زیر می‌باشد:

۱- پیش‌بینی بارش پاییزه با استفاده از مدل‌های منفرد در این مرحله، بر اساس هر یک از شاخص‌های اقلیمی SOI و NINO 3.4 به تنهایی و به صورت ترکیب شده به عنوان متغیرهای پیش‌بینی کننده، مدل‌های منفرد پیش‌بینی کننده بارش اجرا شده است. برای اجرای مدل‌های منفرد از داده‌های ۲۲ و ۱۰ سال به ترتیب برای آموزش (واسنجی) و آزمایش (صحت‌سنجی) مدل‌ها استفاده شده است. مدل‌های منفرد به کار رفته در تحقیق حاضر برای پیش‌بینی بارش، پنج مدل داده مبناء شناخته شده با ساختاری بهینه می‌باشند. ساختار بهینه مدل‌ها به نحوی تعیین شده است که نتایج مرحله صحت‌سنجی دارای کم‌ترین خطا باشد. در جدول ۱، نام، نام اختصاری مدل‌ها و

¹ Nash-Sutcliffe



شکل ۳- الگوریتم مراحل انجام تحقیق

جدول ۱- نام و خصوصیات مدل‌های منفرد پیش‌بینی‌کننده بارش

نام کامل	نام اختصاری	نوع پارامترهای بهینه شده
شبکه عصبی مصنوعی	ANN	وزن‌های اولیه و تعداد نورون‌های لایه میانی
شبکه عصبی رگرسیون تعمیم یافته	GRNN	پارامتر تنظیم مدل (پارامتر سیگما)
رگرسیون بردار پشتیبان	SVR	نوع تابع کرنل، پارامترهای تابع کرنل و پارامتر تنظیم مدل (پارامتر گاما)
K نزدیک‌ترین همسایگی	KNN	وزن متغیرهای پیش‌بینی‌کننده و تعداد همسایگی‌ها (K پارامتر)
رگرسیون خطی	LR	ضریب متغیرهای پیش‌بینی‌کننده

روش وزن‌دهی رتبه‌بندی شده (OWA) با ابعاد n ، نگاشتی از R^n به R است که در آن، n تعداد معیارها (تعداد مدل‌های منفرد) است و برای هر معیار بر اساس معادله ۱، وزنی به صورت $W_i (i=1, n)$ وجود دارد (یاگر، ۱۹۸۸).

$$\sum_{i=1}^n w_i = 1, \quad w_i \in [0,1] \quad (1)$$

برای به‌کارگیری عملگر OWA برای پیش‌بینی بارش، اگر مقدار بارش پیش‌بینی شده توسط مدل منفرد i ام در گام زمانی j ام برابر با a_{ij} باشد، آنگاه بردار نتایج حاصل از n مدل منفرد در هر گام زمانی j برابر با $A = \{a_{1j}, a_{2j}, \dots, a_{nj}\}$ خواهد بود. در این صورت، بردار مرتب شده نزولی (از بهترین نتیجه با کم‌ترین خطا به بدترین نتیجه با بیش‌ترین خطا) حاصل از بردار A در گام زمانی j ام برابر با $B = \{b_{1j}, b_{2j}, \dots, b_{nj}\}$ و بردار وزن‌های متناظر با بردار B ، به صورت $W = \{w_1, w_2, \dots, w_n\}$ می‌باشد. در نهایت عملگر

۳- ترکیب نتایج مدل‌های منفرد بر اساس چهار استراتژی ترکیب مدل‌ها

در این مرحله، نتایج مدل‌های منفرد حاصل از بهترین شاخص اقلیمی پیش‌بینی‌کننده بارش بر اساس چهار استراتژی به‌صورت زیر با یکدیگر ترکیب شده است:

- الف) ترکیب مدل‌ها با استفاده از استراتژی OWA بر اساس وزن‌های محاسبه شده به روش Orness
- ب) ترکیب مدل‌ها با استفاده از استراتژی OWA بر اساس وزن‌های محاسبه شده به روش Orlike
- ج) ترکیب مدل‌ها با استفاده از روش شبکه عصبی مصنوعی
- د) انتخاب بهترین مدل منفرد با کم‌ترین خطا

استراتژی‌های فوق به شرح زیر می‌باشد:

الف و ب- ترکیب مدل‌ها با استفاده از استراتژی وزن‌دهی رتبه‌بندی شده (OWA) بر اساس وزن‌های محاسبه شده به روش‌های Orness و Orlike

در معادله ۵، مقدار پارامتر α باید با توجه به دقت موردنظر در پیش‌بینی، توسط کاربر تعیین شود. از آنجا که نتایج حاصل از مدل‌های منفرد به‌صورت نزولی از بهترین نتیجه به بدترین نتیجه مرتب شده‌اند، لازم است که وزن مدل‌ها نیز به صورت نزولی تنظیم شوند به نحوی که بیش‌ترین وزن به بهترین خروجی مدل‌ها در هرگام زمانی داده شود. با توجه به اینکه برای مقادیر α کوچک‌تر از $0/5$ ، وزن‌های مدل‌ها به صورت صعودی و برای بزرگ‌تر از $0/5$ ، به صورت نزولی هستند، برای تطابق میان وزن‌ها و متغیرها از مقادیر α بزرگتر از $0/5$ برای اجرای فرآیند بهینه‌سازی و تعیین وزن‌ها استفاده شده است. در مقاله حاضر روش بهینه‌سازی فراکوشی الگوریتم ژنتیک برای محاسبه وزن‌های بهینه به کار رفته است.

تعیین وزن مدل‌های منفرد به روش Orlike

روش Orlike یکی از روش‌های اصلی خانواده‌ای از وزن‌های OWA با عنوان S-OWA است که توسط یاجر و فیلو^۳ در سال ۱۹۹۴ ارائه شد. خانواده S-OWA شامل دو نوع روش وزن‌دهی با نام‌های Andlike و Orlike است. در نوع Andlike، بیش‌ترین وزن به بدترین حالت و در نوع Orlike، بیش‌ترین وزن به بهترین حالت اختصاص داده می‌شود. بنابراین، در تحقیق حاضر، از روش Orlike استفاده و بیش‌ترین وزن به بهترین جواب داده شده است. در روش Orlike، مقادیر وزن‌ها و عملگر OWA به‌ترتیب از معادله‌های ۶ و ۷ محاسبه می‌شوند.

$$w_i = \begin{cases} \frac{1}{n}(1-\alpha) + \alpha, & i=1 \\ \frac{1}{n}(1-\alpha), & i=2, \dots, n \end{cases}, \quad \alpha \in [0,1] \quad (6)$$

$$OWA(a_1, a_2, \dots, a_n) = \alpha \text{Max}_i(a_i) + \frac{1}{n}(1-\alpha) \sum_{i=1}^n a_i \quad (7)$$

در این روش، به ازای مقادیر صفر و یک برای پارامتر α ، پارامتر Orness به ترتیب برابر با $0/5$ و یک خواهد شد و این امر نشان می‌دهد که در این روش به ازای تمامی مقادیر α ، وزن بیش‌تری به مدل اول اختصاص می‌یابد. مزیت تعیین وزن در روش OWA به سایر روش‌های تعیین وزن نظیر روش استکینگ (Staking) و یا روش حداقل مربعات در این

OWA به صورت معادله ۲ بر روی نتایج هر گام زمانی z اعمال می‌شود.

$$OWA(a_{1j}, a_{2j}, \dots, a_{nj}) = \sum_{i=1}^n w_i b_{ij} \quad (2)$$

بنابراین، در این روش، در هر گام زمانی، وزن اختصاص یافته به مدل‌های منفرد تغییر می‌نماید. از آنجایی که برای وزن‌دهی به مدل‌های منفرد با روش OWA، ترکیب‌های متفاوتی از وزن‌ها وجود دارد، یاجر^۱ (۱۹۸۸) برای تعیین نحوه پراکندگی وزن‌ها حول مقدار میانه آن‌ها، پارامتر Orness را به صورت معادله ۳ تعریف نمود.

$$\text{Orness}(w) = \frac{1}{n-1} \sum_{i=1}^n (n-i) w_i \quad 0 \leq \text{Orness}(w) \leq 1 \quad (3)$$

مقادیر صفر و یک این پارامتر به ترتیب نشان‌دهنده وزن برابر با یک به بدترین و بهترین حالت (خروجی مدل) هستند. در این شرایط، وزن سایر مدل‌ها برابر با صفر خواهد بود. مقدار $0/5$ برای این پارامتر نشان می‌دهد که یا همگی وزن‌ها برابر هستند و یا وزن‌ها به صورت توزیع نرمال حول میانه قرار دارند. بنابراین مقادیر میان $0/5$ و یک برای این پارامتر نشان می‌دهد که توزیع وزن‌ها دارای چولگی مثبت است و این به این معناست که وزن بیش‌تری به مدل بهتر اختصاص یافته است. تعیین وزن‌ها در روش OWA به شیوه‌های متفاوتی صورت می‌گیرد. در مقاله حاضر دو روش اصلی‌ترین روش‌های تعیین وزن به‌کار رفته است که به صورت زیر می‌باشد:

تعیین وزن مدل‌های منفرد به روش Orness

هاگان^۲ (۱۹۸۸) برای تعیین بهترین وزن‌ها از مدل بهینه‌سازی زیر استفاده نمود که در آن به ازای مقدار مشخصی از پارامتر Orness، بیشینه مقدار برای پارامتر پراکندگی (Disp) ایجاد شود.

$$\text{Maximize} : - \sum_{i=1}^n w_i \ln w_i \quad (4)$$

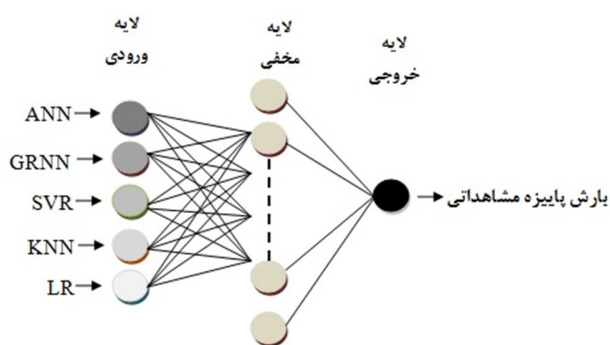
$$\text{Subject to} : \frac{1}{n-1} \sum_{i=1}^n (n-i) w_i = \alpha \quad 0 \leq \alpha \leq 1 \quad (5)$$

$$\sum_{i=1}^n w_i = 1, \quad 0 \leq w_i \leq 1, \quad i=1,2,\dots,n$$

¹ Yager

² O'Hagan

³ Yager and Filev



شکل ۴- ساختار شبکه عصبی مورد استفاده برای ترکیب مدل‌های منفرد

۴- ارزیابی نتایج استراتژی‌های ترکیب مدل‌ها

در این مرحله نیز نتایج حاصل از استراتژی‌های ترکیب مدل‌ها بر اساس سه معیار نش-ساتکلیف، ریشه متوسط مربعات خطا (RMSE) و ضریب تبیین (R^2) مورد ارزیابی قرار گرفته و بهترین استراتژی تعیین شده است.

نتایج و بحث

نتایج حاصل از اجرای مدل‌های منفرد

همان‌طور که در بخش مواد و روش‌ها بیان شد، برای اجرای مدل‌های منفرد از داده‌های ۲۲ و ۱۰ سال به ترتیب برای آموزش (واسنجی) و آزمایش (صحت‌سنجی) مدل‌ها استفاده شده است. همچنین، برای تعیین بهترین متغیر پیش‌بینی کننده، هر یک از مدل‌های منفرد بر مبنای سه نوع متغیر پیش‌بینی کننده شامل متوسط تابستانه هر یک از شاخص‌های SOI و NINO 3.4 به تنهایی و به صورت ترکیب شده اجرا شده است. از آنجا که هدف این تحقیق، افزایش دقت نتایج در مرحله صحت‌سنجی است، نتایج حاصل از اجرای مدل‌های منفرد برای پیش‌بینی بارش پاییزه در مرحله صحت‌سنجی بر اساس هر یک از متغیرهای پیش‌بینی کننده در جدول ۲ آورده شده است. با توجه به جدول ۲ مشاهده می‌شود که بر اساس هر سه معیار ارزیابی نتایج، در تمامی مدل‌های منفرد به جز KNN دقت نتایج حاصل از شاخص NINO 3.4 بیش‌تر از دقت نتایج حاصل از شاخص SOI است (هر چه شاخص نش-ساتکلیف و ضریب همبستگی به یک نزدیک‌تر و شاخص RMSE به صفر نزدیک‌تر باشد، دقت نتایج بیش‌تر است). همچنین، مقایسه

است که این روش به کاربر این امکان را می‌دهد که با توجه به مقدار پارامتر α ، به تنوع وسیعی از ترکیب وزن‌ها دست یابد و با توجه به اهمیت مدل‌ها، به هر مدل وزن مناسب را اختصاص دهد. همچنین، در این روش مقادیر وزن مدل‌ها به صورت مستقل از میزان خطای مدل‌ها تعیین می‌شود.

ج- ترکیب مدل‌ها با استفاده از روش شبکه عصبی مصنوعی

برای ترکیب مدل‌های منفرد با استفاده از روش شبکه عصبی، یک مدل شبکه عصبی مصنوعی سه لایه پیش‌خور با ساختاری بهینه از نظر تعداد نورون‌ها و وزن‌های اولیه استفاده شده است و ساختار بهینه به نحوی تعیین شده است که نتایج مرحله صحت‌سنجی از بیش‌ترین دقت برخوردار باشد. برای ترکیب مدل‌ها با شبکه عصبی، نتایج حاصل از پیش‌بینی بارش توسط مدل‌های منفرد بر اساس بهترین متغیر پیش‌بینی کننده به عنوان ورودی و مقادیر بارش پاییزه مشاهداتی به عنوان هدف (خروجی) به مدل شبکه عصبی معرفی شدند و برای آموزش و آزمایش این مدل، از خروجی مدل‌های منفرد در دوره‌های واسنجی و صحت‌سنجی استفاده شده است. ساختار شبکه عصبی به کار رفته در مقاله حاضر در شکل ۴ نشان داده شده است.

د- انتخاب بهترین مدل منفرد با کم‌ترین خطا

در روش‌های میانگین‌گیری وزنی از مدل‌های منفرد، از روش‌هایی نظیر برنامه‌ریزی خطی و استکینگ برای تعیین وزن مدل‌ها استفاده شده است (عزمی و همکاران، ۲۰۱۰) که در این روش‌ها، وزن مدل‌ها بر اساس میزان خطای آن‌ها تعیین می‌شود. در نتیجه وزنی نزدیک به یک به بهترین مدل (مدلی با خطاهای کم‌تر) و وزنی نزدیک به صفر به سایر مدل‌ها اختصاص می‌یابد. بنابراین در مقاله حاضر از استراتژی بهترین مدل منفرد با کم‌ترین خطا استفاده شده است که در آن، وزن یک، به بهترین مدل منفرد و وزن صفر به سایر مدل‌های منفرد اختصاص داده می‌شود.

متغیر پیش‌بینی کننده NINO 3.4 از دقت بسیار بالاتری نسبت به حالت به‌کارگیری دو شاخص برخوردار است؛ به طوری که به ازای NINO 3.4 شاخص نش- ساتکلیف برای ANN و LR به‌ترتیب برابر با ۰/۴۸۸ و ۰/۲۵۷ است درحالی‌که به ازای ترکیب SOI و NINO 3.4، مقدار این شاخص برای دو مدل مذکور به‌ترتیب برابر با ۰/۱۹۵ و ۰/۶۹۸- است.

نتایج حاصل از NINO 3.4 با نتایج حاصل از ترکیب دو شاخص SOI و NINO 3.4 نشان می‌دهد که در تمامی مدل‌های منفرد به‌جز KNN، به ازای متغیر پیش‌بینی کننده NINO 3.4، ضریب همبستگی مقادیر مشاهداتی و مدل‌سازی شده بزرگ‌تر از حالت به‌کارگیری ترکیب دو شاخص است. بر اساس دو شاخص نش- ساتکلیف و RMSE نیز مشاهده می‌شود که نتایج دو مدل ANN و LR به ازای

جدول ۲- نتایج مدل‌های منفرد در مرحله صحت‌سنجی برای پیش‌بینی بارش پاییزه بر اساس متغیرهای پیش‌بینی کننده اقلیم

نام مدل منفرد					شاخص ارزیابی مدل‌ها	متغیر پیش‌بینی کننده
LR	KNN	SVR	GRNN	ANN		
-۰/۰۷۳	-۰/۰۸۰	۰/۱۴۷	۰/۱۲۴	۰/۰۹۲	Nash-Sutcliff	SOI
۰/۷۶۹	۰/۷۷۱	۰/۶۸۵	۰/۶۹۴	۰/۷۰۷	RMSE	
۰/۳۳۸	۰/۱۷۹	۰/۳۸۷	۰/۳۵۴	۰/۳۷۹	Correlation Coeff	
۰/۲۵۷	-۰/۴۷۷	۰/۲۲۵	۰/۱۷۳	۰/۴۸۸	Nash-Sutcliff	NINO 3.4
۰/۶۴۰	۰/۹۰۱	۰/۶۵۳	۰/۶۷۵	۰/۵۳۱	RMSE	
۰/۵۵۲	۰/۴۰۶	۰/۵۵۲	۰/۵۵۲	۰/۷۶۱	Correlation Coeff	
-۰/۶۹۸	۰/۲۱۱	۰/۲۱۸	۰/۱۸۲	۰/۱۹۵	Nash-Sutcliff	SOI+NINO 3.4
۰/۹۶۷	۰/۶۵۹	۰/۶۵۶	۰/۶۷۱	۰/۶۶۶	RMSE	
۰/۱۵۶	۰/۴۹۵	۰/۵۰۴	۰/۴۴۲	۰/۴۴۳	Correlation Coeff	

شایان ذکر است که مقایسه نتایج حاصل از مدل‌های منفرد به ازای شاخص اقلیمی NINO 3.4 نیز نشان می‌دهد که مدل شبکه عصبی مصنوعی برای پیش‌بینی بارش پاییزه از دقت بسیار بیش‌تری نسبت به سایر مدل‌های منفرد برخوردار است ولی از آنجا که از پیش‌بینی‌های مناسب صورت گرفته به‌وسیله سایر مدل‌ها نیز نمی‌توان صرف‌نظر نمود، برای ارتقاء نتایج پیش‌بینی، از استراتژی ترکیب مدل‌ها استفاده شده است.

نتایج حاصل از استراتژی‌های ترکیب مدل‌ها

استخراج وزن‌های مدل‌های منفرد با روش‌های Orness و Orlike

در روش Orness، وزن‌های لازم برای پنج مدل منفرد بر اساس معادلات ۴ و ۵ و با استفاده از روش بهینه‌سازی الگوریتم ژنتیک به ازای مقادیر α در بازه ۰/۵ تا ۰/۹ و در روش Orlike نیز وزن‌ها بر اساس معادله ۶ به ازای مقادیر α در بازه ۰/۱ تا ۰/۹ محاسبه شده‌اند. وزن‌های حاصل از این دو روش به صورت نمودار در شکل ۵ (الف و ب) نشان

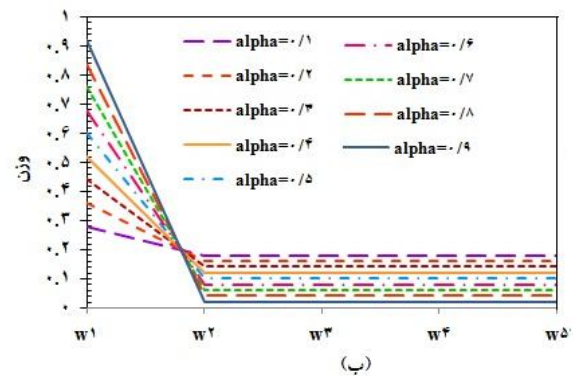

همچنین، ارزیابی نتایج مدل SVR بر اساس دو شاخص نش- ساتکلیف و RMSE نیز نشان می‌دهد که به‌کارگیری متغیر پیش‌بینی کننده NINO 3.4 سبب ایجاد نتایج با دقت بالاتر نسبت به حالت ترکیب دو مدل می‌شود. ارزیابی نتایج مدل GRNN بر اساس دو شاخص نش- ساتکلیف و RMSE نیز نمایانگر این نکته است که دقت نتایج حاصل از NINO 3.4، ۵ درصد کم‌تر از نتایج حاصل از ترکیب SOI و NINO 3.4 است. در مقابل، نتایج مدل KNN نشان می‌دهد که به‌کارگیری ترکیب دو شاخص اقلیمی SOI و NINO 3.4 سبب ایجاد نتایج با دقت بالاتر نسبت به دو حالت دیگر می‌شود. بنابراین، به‌طور کلی، مقایسه نتایج حاصل از سه نوع متغیر پیش‌بینی کننده در پنج مدل منفرد نشان می‌دهد که در تمامی مدل‌ها به‌جز مدل KNN، به‌کارگیری شاخص NINO 3.4 سبب ایجاد نتایج دقیق‌تری نسبت به دو نوع پیش‌بینی کننده دیگر می‌شود. در نتیجه، نتایج مدل‌های منفرد به ازای شاخص اقلیمی NINO 3.4 به‌عنوان دقیق‌ترین نتایج انتخاب و در مرحله ترکیب مدل‌ها استفاده شده است.

مقادیر α ، وزن بهترین مدل (بهترین جواب) از سایر مدل‌ها بیش‌تر و وزن سایر مدل‌ها (سایر جواب‌ها) با هم برابر است. در این روش، وزن بهترین مدل از $0/28$ به ازای α برابر با $0/1$ تا $0/92$ به ازای α برابر با $0/9$ تغییر می‌نماید.

ارزیابی نتایج استراتژی‌های ترکیب مدل‌ها

با به‌کارگیری نتایج حاصل از پیش‌بینی بارش پاییزه توسط مدل‌های منفرد بر اساس متغیر اقلیمی پیش‌بینی کننده NINO 3.4، استراتژی‌های ترکیب مدل‌ها اجرا شده است. نتایج به‌دست آمده از استراتژی وزن‌دهی رتبه‌بندی شده به مدل‌های منفرد بر مبنای وزن‌های محاسبه شده به روش Orness به ازای مقادیر α بزرگ‌تر مساوی $0/5$ ، در جدول ۳ آورده شده و با نتایج حاصل از استراتژی‌های ترکیب مدل‌ها با شبکه عصبی و انتخاب بهترین مدل منفرد مقایسه شده است. از آنجایی که هدف از به‌کارگیری استراتژی‌های ترکیب مدل‌ها، ارتقای دقت نتایج پیش‌بینی در مرحله صحت‌سنجی است، در جدول ۳ نتایج بخش صحت‌سنجی استراتژی‌های مذکور نشان داده شده است. با توجه به جدول ۳ مشاهده می‌شود که بر اساس هر سه معیار ارزیابی مدل‌ها، نتایج حاصل از استراتژی وزن‌دهی رتبه‌بندی شده با روش Orness به ازای تمامی مقادیر α در بازه $0/5$ تا $0/9$ از دقت بالاتری نسبت به نتایج استراتژی ترکیب مدل‌ها با شبکه عصبی برخوردار است. همچنین، به ازای مقادیر $0/8$ و $0/9$ برای پارامتر α ، دقت نتایج حاصل از استراتژی ترکیب مدل‌ها با روش Orness بیش‌تر از نتایج به‌دست آمده از استراتژی انتخاب بهترین مدل منفرد است و به ازای α برابر با $0/9$ ، بیش‌ترین دقت برای نتایج حاصله ایجاد شده است و در این حالت دقت نتایج بر اساس شاخص‌های ارزیابی نش-ساتکلیف و RMSE برابر با $0/612$ و $0/462$ می‌باشد و میزان ضریب تبیین مقادیر محاسبه شده در این روش با مقادیر مشاهداتی برابر با $0/861$ است. در جدول ۴ نیز نتایج به‌دست آمده از بخش صحت‌سنجی استراتژی وزن‌دهی رتبه‌بندی شده با روش Orlike به ازای مقادیر α در بازه $0/1$ تا $0/9$ نشان داده شده و با نتایج حاصل از استراتژی‌های ترکیب مدل‌ها با شبکه عصبی و انتخاب بهترین مدل منفرد مقایسه شده است.

داده شده است. در نمودارهای شکل ۵، محور افقی نماینده وزن مدل‌ها است که از w_1 تا w_5 به ترتیب به نتایج بهترین تا بدترین مدل منفرد (از نظر میزان خطا) اعمال می‌شود و محور عمودی نشان‌دهنده مقدار وزن‌ها می‌باشد.



شکل ۵- نمودار وزن‌های حاصل از روش‌های (الف) Orness و (ب) Orlike

در نمودار وزن‌های روش Orness (شکل الف)، مشاهده می‌شود که به ازای مقدار $0/5$ برای پارامتر α ، وزن تمامی مدل‌ها تقریباً با هم برابر است. با زیاد شدن مقدار پارامتر α ، وزن تعیین شده برای بهترین مدل (بهترین جواب)، بیش‌تر شده و از وزن سایر مدل‌ها (سایر جواب‌ها) کاسته می‌شود؛ در این روش، وزن بهترین مدل از $0/204$ به ازای α برابر با $0/5$ تا $0/724$ به ازای α برابر با $0/9$ تغییر می‌نماید. از آنجا که به ازای α کوچک‌تر از $0/5$ وزن بهترین مدل (بهترین جواب) از سایرین کوچک‌تر و وزن بدترین مدل (بدترین جواب) بزرگ‌تر می‌شود (بر اساس معادله ۳)، در روش Orness از مقادیر α بزرگ‌تر مساوی $0/5$ استفاده شده است. ولی با توجه به نمودار وزن‌های روش Orlike (شکل ب) مشاهده می‌شود که در این روش به ازای تمامی

جدول ۳- مقایسه نتایج استراتژی ترکیب مدل‌ها با روش Orness با استراتژی‌های شبکه عصبی و انتخاب بهترین مدل منفرد


متغیر پیش‌بینی شونده	شاخص‌های ارزیابی نتایج	استراتژی ۱: ترکیب مدل‌ها با روش Orness					استراتژی ۳	استراتژی ۴
		$\alpha=0/9$	$\alpha=0/8$	$\alpha=0/7$	$\alpha=0/6$	$\alpha=0/5$		
بارش پاییزه	Nash-Sutcliffe	۰/۲۷۸	۰/۳۷۴	۰/۴۶۳	۰/۵۴۰	۰/۶۱۲	-۰/۱۷۳	۰/۴۸۸
	RMSE	۰/۶۳۰	۰/۵۸۷	۰/۵۴۴	۰/۵۰۳	۰/۴۶۲	۰/۸۰۳	۰/۵۳۱
	Correlation	۰/۶۲۰	۰/۶۹۵	۰/۷۶۳	۰/۸۱۸	۰/۸۶۱	۰/۴۸۷	۰/۷۶۱

جدول ۴- مقایسه نتایج استراتژی ترکیب مدل‌ها با روش Orlike با استراتژی‌های شبکه عصبی و انتخاب بهترین مدل منفرد

متغیر پیش‌بینی شونده	شاخص‌های ارزیابی نتایج	استراتژی ۲: ترکیب مدل‌ها با روش Orlike										استراتژی ۳	استراتژی ۴
		$\alpha=0/9$	$\alpha=0/8$	$\alpha=0/7$	$\alpha=0/6$	$\alpha=0/5$	$\alpha=0/4$	$\alpha=0/3$	$\alpha=0/2$	$\alpha=0/1$	ترکیب مدل‌ها با شبکه عصبی مصنوعی		
بارش پاییزه	Nash-Sutcliffe	۰/۳۳۰	۰/۳۷۹	۰/۴۲۶	۰/۴۷۰	۰/۵۱۱	۰/۵۴۹	۰/۵۸۵	۰/۶۱۸	۰/۶۴۹	-۰/۱۷۳	۰/۴۸۸	
	RMSE	۰/۶۰۷	۰/۵۸۵	۰/۵۶۲	۰/۵۴۰	۰/۵۱۹	۰/۴۹۸	۰/۴۷۸	۰/۴۵۸	۰/۴۴۰	۰/۸۰۳	۰/۵۳۱	
	Correlation	۰/۶۶۲	۰/۷۰۱	۰/۷۳۷	۰/۷۶۹	۰/۷۹۸	۰/۸۲۳	۰/۸۴۴	۰/۸۶۲	۰/۸۷۶	۰/۴۸۷	۰/۷۶۱	

نتایج به‌دست آمده از روش Orlike از دقت بالاتری نسبت به روش Orness برخوردار است؛ به‌طوری که به ازای α برابر با ۰/۱ در روش Orlike دقت نتایج حاصله بر اساس هر سه معیار ارزیابی بیشتر از نتایج روش Orness به ازای α برابر با ۰/۵ است. دقت نتایج به‌دست آمده از روش Orlike بر حسب شاخص نش به ازای α برابر با ۰/۵، ۸۳/۸ درصد بیشتر از دقت نتایج به‌دست آمده از روش Orness به ازای همین مقدار برای پارامتر α است. همچنین، در روش Orness، فقط به ازای مقادیر ۰/۸ و ۰/۹ برای پارامتر α ، دقت نتایج حاصله بیشتر از دقت نتایج به‌دست آمده از بهترین مدل منفرد است در حالی که در روش Orlike، به ازای مقادیر α در بازه ۰/۵ تا ۰/۹، دقت نتایج به‌دست آمده بیشتر از نتایج بهترین مدل منفرد می‌باشد. با این وجود، در هر دو روش، بهترین نتیجه به ازای مقدار ۰/۹ برای پارامتر α ایجاد شده است. مقایسه بهترین نتیجه به‌دست آمده از این دو روش نشان می‌دهد که روش Orness دقت نتایج بهترین مدل منفرد را ۲۵/۴ درصد افزایش داده است در حالی که روش Orlike سبب افزایش دقت نتایج به میزان ۳۳ درصد نسبت به بهترین مدل منفرد شده است.

در جدول ۴ نیز مشاهده می‌شود که بر اساس هر سه معیار ارزیابی مدل‌ها، نتایج حاصل از استراتژی وزن‌دهی رتبه‌بندی شده با روش Orlike به ازای تمامی مقادیر α در بازه ۰/۱ تا ۰/۹ از دقت بالاتری نسبت به نتایج استراتژی ترکیب مدل‌ها با شبکه عصبی برخوردار است. همچنین، به ازای مقادیر α در بازه ۰/۵ تا ۰/۹، دقت نتایج حاصل از استراتژی ترکیب مدل‌ها با روش Orlike بیشتر از نتایج به دست آمده از استراتژی انتخاب بهترین مدل منفرد می‌باشد. در این روش، بیش‌ترین دقت برای نتایج به ازای α برابر با ۰/۹ ایجاد شده است و در این حالت دقت نتایج بر اساس شاخص‌های ارزیابی نش- ساتکلیف و RMSE برابر با ۰/۶۴۹ و ۰/۴۴۰ و میزان ضریب تبیین مقادیر محاسبه شده در این روش با مقادیر مشاهداتی برابر با ۰/۸۷۶ است. در شکل ۶، بهترین نتایج به‌دست آمده از استراتژی‌های ۱ و ۲ ترکیب مدل‌ها (به ازای $\alpha=0/9$) در بخش صحت‌سنجی با نتایج حاصل از استراتژی‌های ۳ و ۴ در این بخش مقایسه شده است. شایان ذکر است که برای ترسیم گراف‌های این شکل، از مقادیر بارش نرمال استاندارد استفاده شده است. مقایسه نتایج حاصل از استراتژی وزن‌دهی رتبه‌بندی شده با دو روش Orness و Orlike (جدول ۳ و ۴) نشان می‌دهد که



شکل ۶- مقادیر پیش‌بینی شده بارش پاییزه در بخش صحت‌سنجی توسط استراتژی‌های ترکیب مدل‌های (الف) Orness (به ازای $\alpha = 0.9$)، (ب) Orlike (به ازای $\alpha = 0.9$)، (ج) شبکه عصبی و (د) بهترین مدل منفرد

نتیجه‌گیری

پیش‌بینی بارش پاییزه در برنامه‌ریزی‌های بلندمدت منابع آب برای تخصیص آب به بخش کشاورزی و تعیین نوع الگوی کشت دیم پاییزه از اهمیت ویژه‌ای برخوردار است. در این مقاله، تکنیک ترکیب مدل‌ها برای افزایش دقت پیش‌بینی بارش پاییزه در زیرحوضه سیمره از حوضه کرخه مورد ارزیابی قرار گرفته است. به این منظور، مدل‌های شبکه عصبی مصنوعی، شبکه عصبی رگرسیون تعمیم یافته، رگرسیون بردار پشتیبان، K نزدیک‌ترین همسایگی و رگرسیون خطی با ساختار بهینه به‌عنوان مدل‌های منفرد پیش‌بینی‌کننده بارش مورد استفاده قرار گرفته و با به‌کارگیری متوسط تابستانه هر یک از شاخص‌های نوسانات جنوبی (SOI) و NINO 3.4 و ترکیب آن‌ها، پیش‌بینی بارش پاییزه توسط هر یک از مدل‌های منفرد صورت گرفته است. برای ترکیب نتایج مدل‌های منفرد، در مقاله حاضر از استراتژی وزن‌دهی رتبه‌بندی شده به مدل‌های منفرد (OWA) استفاده شده و کارایی دو روش تعیین وزن مدل‌ها

با نام‌های Orness و Orlike مورد ارزیابی قرار گرفته است. همچنین، برای ارزیابی میزان کارایی استراتژی وزن‌دهی رتبه‌بندی شده برای ترکیب مدل‌ها، نتایج این استراتژی با دو استراتژی ترکیب مدل‌ها با شبکه عصبی و انتخاب بهترین مدل منفرد نیز مقایسه شده است. بر اساس نتایج به‌دست آمده از مقاله حاضر، متوسط تابستانه شاخص NINO3.4، مناسب‌ترین متغیر پیش‌بینی‌کننده برای پیش‌بینی بارش پاییزه در زیرحوضه سیمره شناخته شده است؛ زیرا با به‌کارگیری این شاخص، دقت نتایج به‌دست آمده از تمامی مدل‌های منفرد به‌جز KNN در مرحله صحت‌سنجی بیش‌تر از نتایج حاصل از متغیرهای پیش‌بینی‌کننده دیگر می‌باشد. همچنین، بر مبنای هر سه معیار ارزیابی نتایج نش-ساتکلیف، RMSE و ضریب همبستگی، دقت نتایج به‌دست آمده از استراتژی وزن‌دهی رتبه‌بندی شده بر اساس هر دو روش Orness و Orlike به ازای تمامی مقادیر شاخص اورنس (پارامتر α)، بیش‌تر از نتایج استراتژی ترکیب مدل‌ها با شبکه عصبی مصنوعی می‌باشد. مقایسه نتایج

منابع

- عزیزی، ق. ۱۳۷۹. ال نینو و دوره‌های خشکسالی - ترسالی در ایران. نشریه پژوهش‌های جغرافیایی، ۳۸: ۷۱-۸۴.
- فاتحی مرج، ا، مهدیان، م. ح. ۱۳۸۸. پیش‌بینی بارش پاییزه با استفاده از شاخص‌های انسو به روش شبکه عصبی در حوضه دریاچه ارومیه. نشریه پژوهش‌های آبخیزداری، ۸۴: ۴۲-۵۲.
- فتاحی، ا.، صداقت کردار، ع.، دلاور، م. ۱۳۸۷. پیش‌بینی بلندمدت بارش با استفاده از شبکه‌های عصبی مصنوعی (مطالعه موردی جنوب غرب ایران). نشریه پژوهش و سازندگی در منابع طبیعی، ۸۰: ۴۴-۵۰.
- کوره پزان دزفولی، ا. ۱۳۸۲. تأثیر سیگنال‌های هواشناسی در پیش‌بینی تغییرات بارش، پایان‌نامه کارشناسی ارشد، دانشگاه امیرکبیر.
- مدرسی، ف.، عراقی‌نژاد، ش.، ابراهیمی، ک. ۱۳۹۴. ارتقاء دقت پیش‌بینی جریان ماهانه با استفاده از Ornees Method برای ترکیب مدل‌ها (مطالعه موردی: پیش‌بینی جریان ورودی به سد سیمره). نخستین کنگره ملی آبیاری و زهکشی ایران، ۲۳ و ۲۴ اردیبهشت، دانشگاه فردوسی مشهد.
- Abrahart, R. J., See, L. 2002. Multi-model data fusion for river flow forecasting: an evaluation of six alternative methods based on two contrasting catchments. *Hydrol. Earth. Syst. Sci.*, 6: 655-670.
- Allen, R. J., Bread, G. S., Close, A., Herczeg, A. L., Jones, P. D., Simpson, H. J. 1996. Mean sea level pressure indices of the El Nino/Southern Oscillation: Relevance to stream discharge in Southeastern Australia. CSIRO Australia, Division of Water Resources, Report No. 96/1.
- Araghinejad, S. 2014. Data-derived modeling: using MATLAB in water resources and environmental engineering. Springer, New York. 297.
- Araghinejad, S., Burn, D. H., Karamouz, M. 2006. Long-lead probabilistic forecasting of streamflow using ocean-atmospheric and hydrological predictors. *J. Water. Resour. Res.*, 42 (3), W03431, DOI:10.1029/2004WR003853.
- Azmi, M., Araghinejad, S., Kholghi, M. 2010. Multi model data fusion for hydrological forecasting using K- nearest neighbor method. *Iran. J. Sci. Tech.* 34 (B1): 81-92.
- Chen, L., Ye, L., Singh, V., Zhou, J., Guo, S. 2014. Determination of Input for Artificial Neural Networks for Flood Forecasting Using the Copula

حاصل از دو روش Orlike و Orness نشان می‌دهد که دقت نتایج حاصل از روش Orlike بیش‌تر از نتایج روش Orness است به نحوی که در روش Orness به ازای مقدار ۰/۸ و ۰/۹ برای پارامتر α دقت نتایج حاصل از پیش‌بینی بارش بیش‌تر از دقت نتایج به‌دست آمده از بهترین مدل منفرد است در حالی‌که در روش Orlike به ازای مقادیر ۰/۵ تا ۰/۹ برای پارامتر α ، دقت نتایج بیش‌تر از بهترین مدل منفرد می‌باشد. همچنین، دقت نتایج به‌دست آمده از روش Orlike بر حسب شاخص نش به ازای α برابر با ۰/۵، ۸۳/۸ درصد بیش‌تر از دقت نتایج به‌دست آمده از روش Orness به ازای همین مقدار برای پارامتر α است. با این وجود، در هر دو روش، بیش‌ترین افزایش دقت به ازای مقدار ۰/۹ برای پارامتر α رخ داده که در این حالت بر اساس وزن‌های دو روش Orlike و Orness، دقت نتایج بهترین مدل منفرد به ترتیب ۲۵/۴ و ۳۳ درصد افزایش یافته است. افزایش دقت نتایج در استراتژی‌های ترکیب مدل‌ها با روش‌های وزن‌دهی رتبه‌بندی شده نسبت به نتایج بهترین مدل منفرد نشان می‌دهد که در بهترین مدل منفرد، لزوماً بهترین نتایج در تمامی گام‌های زمانی ایجاد نمی‌شود. بنابراین در صورتی که از وزن ثابتی در تمامی گام‌های زمانی برای وزن‌دهی به مدل‌های منفرد استفاده شود (نظیر روش‌های وزن‌دهی بر مبنای برنامه‌ریزی خطی و استکینگ) بهترین مدل منفرد بیش‌ترین وزن را دریافت کرده و در نتیجه، نتایج حاصل از روش وزن‌دهی نسبت به نتایج بهترین مدل منفرد ارتقای چندانی نمی‌یابد؛ ولی در مقاله حاضر با استفاده از روش وزن‌دهی رتبه‌بندی شده و تعیین وزن مدل‌ها به صورت مستقل از میزان خطای آن‌ها و نیز، تغییر وزن مدل‌ها در هر گام زمانی، از تمامی قابلیت همه مدل‌های منفرد در راستای ایجاد نتایج دقیق‌تر استفاده شده و بنابراین، دقت نتایج حاصله از استراتژی ترکیب مدل‌ها به صورت قابل توجهی نسبت به نتایج بهترین مدل منفرد افزایش یافته است.

سپاسگزاری

به این وسیله از دانشگاه تهران و شرکت مدیریت منابع آب ایران به دلیل تأمین داده‌ها و امکانات لازم جهت انجام این تحقیق و تهیه مقالات آن تشکر و قدردانی می‌شود.

- by Sea Surface Temperature of the Mediterranean Sea. *J. Hydrol. Eng.*, 19(8), 05014005.
- Mitsukura, Y., Ito, S., Fukumi, M., Akamatsu, N. 2002. Genetic fog occurrence forecasting system using a LVQ network. in: M.H. Hamza (Ed.), *Appl. Informat. J., Track*, 285- 351.
- Nazemosadat, M. J., Cordery, I. 2000. On the relationships between Enso and autumn rainfall in Iran. *Int. J. Climatol.*, 20: 47-61.
- O'Hagan, M. 1988. Aggregating template rule antecedents in real-time expert systems with fuzzy set logic. In: *Proc 22nd Annual IEEE Asilomar Conference on Signals, Systems and Computers*. Pacific Grove, CA: IEEE and Maple Press; pp 681-689.
- Redmond, K. T., Koch, R. W. 1991. Surface climate and streamflow variability in the western United States and their relationship to Large-Scale circulation indices. *Water. Resour. Res.*, 27:2381-2399.
- Renguang, B. W., Xiuhua, F. 2000. Pacific East Asian teleconnectio: How does ENSO affect East Asian climate. *J. Clim.*, 13(20): 4073-4090.
- Ropelewski, C. F., Halpert, M. S. 1989. Precipitation pattern associated with the high index phase of the southern oscillation. *J. Clim.*, 2:268-284.
- See, L., Abrahart, R. J. 2001. Multi-model data fusion for hydrological forecasting. *Comput. Geosci.*, 27: 987-994.
- Shamseldin, A. Y., O'Connor, K. M., Nasr, A. E. 2007. A comparative study of three neural network forecast combination methods for simulated river flows of different rainfall-runoff models. *Hydrol. Sci. J.*, 52(5): 896-916.
- Su, J., Wang, X., Liang, Y., Chen, B. 2014. GA-Based Support Vector Machine Model for the Prediction of Monthly Reservoir Storage. *J. Hydrol. Eng.*, 19(7): 1430-1437.
- Wu, C.L., Chau, K.W., Fan, C. 2010. Prediction of rainfall time series using modular artificial neural networks coupled with data-preprocessing techniques. *J. Hydrol.*, 389 (1-2): 146-167.
- Xiong, L., Shamseldin, A. Y., O'Connor, K. M. 2001. A non-linear combination of the forecasts of rainfall-runoff models by the first-order Takagi-Sugeno fuzzy system. *J. Hydrol.*, 245: 196-217.
- Yager, R. R. 1988. On ordered weighted averaging aggregation operators in multi criteria decision making. *IEEE Trans. Syst. Man. Cybern.*, 18: 183-190.
- Yager, R. R., Filev, D. P. 1994. Parameterized "andlike" and "orlike" OWA operators. *Int. Gen. Syst.*, 22: 297-316.
- Zhou, L. G. Chen, H. Y. 2011. Continuous generalized OWA operator and its application to decision making. *Fuzzy. Set. Syst.*, 168: 18-34.
- Entropy Method. *J. Hydrol. Eng.*, 19(11), 04014021.
- Chiclana, F., Herrera-Viedma, E., Herrera, F., Alonso, S. 2007. Some induced ordered weighted averaging operators and their use for solving group decision-making problems based on fuzzy preference relations. *Eur. J. Oper. Res.*, 182: 383-399.
- Chiew, F. H. S., Piechota, T. C., Dracup, J. A., McMahon, T. A. 1998. El Nino Southern oscillation and Australian drought: Link and potential for forecasting system. *Comput. Aided. Civ. Infrastruct. Eng.*, 15(5), 355-364.
- Dasarathy, B. V. 1994. *Decision Fusion*. IEEE Computer Society Press, Los Alamitos, California.
- Goswami, M., O'Connor, K. M. 2007. Real-time flow forecasting in the absence of quantitative precipitation forecasts: a multi-model approach. *J. Hydrol.*, 334: 125-140.
- Hall, D. L., Linas, J. 1997. An introduction to multisensor data fusion. In *proceedings of the IEEE*. 85: 6-10.
- Khalili, A., Gill, M. K., McKee, M. 2005. New applications for information fusion and soil moisture forecasting. 8th International Conference on Information Fusion. Philadelphia, 25-28 July.
- Kisi, O., Cimen, M. 2012. Precipitation forecasting by using wavelet-support vector machine conjunction model. *Eng. Appl. Artif. Intell.*, 25(4): 783-792.
- Kripalani, R. H., Kulkarni, A. 1997. Rainfall variability over Southern-East Asia, connections with India monsoon and ENSO extremes: new perspective. *Int. J. Climatol.*, 20(1): 47-61.
- Leslie, W. G., Robinson, A. R., Haley Jr, P. J., Logutov, O., Moreno, P. A., Lermusiaux, P. F. J., Coelho, E. 2008. Verification and training of real-time forecasting of multi-scale ocean dynamics for maritime rapid environmental assessment. *J. Mar. Syst.*, 69: 3-16.
- Makropoulos, C. K., Butler, D. 2006. Spatial ordered weighted averaging: Incorporating spatially variable attitude towards risk in spatial multicriteria decision-making. *Environ. Model. Softw.*, 21(1): 69-84.
- Mandic, D. P., Javidi, S., Goh, S. L., Kuh, A. Aihara, K. 2009. Complex-valued prediction of wind profile using augmented complex statistics. *Renew. Energ.*, 34: 196-201.
- Mariotti, A., Zeng, N., Lau, K. M. 2002. Euro-Mediterranean rainfall and ENSO- a seasonally varying relationship. *South African J. Sci.*, 29 (12): 591-594.
- Meidani, E., Araghinejad, S. 2014. Long-Lead Streamflow Forecasting in the Southwest of Iran



Assessment of model fusion strategy for increasing the accuracy of autumn rainfall forecasting

F. Modaresi¹, S. Araghinejad^{2*}, K. Ebrahimi²

Received: 17/06/2015

Accepted: 10/01/2016

Abstract

Autumn precipitation forecasting plays a key role in agricultural planning especially rainfed farming feasibility studies. In this study, model fusion technique has been used in order to increase the accuracy of autumn precipitation forecast. Based on two teleconnection signals of SOI and NINO 3.4 as predictors, five models including; Artificial Neural Network (ANN), Generalized Regression Neural Network (GRNN), Support Vector Regression (SVR), K-Nearest Neighbor (KNN), and Linear Regression (LR) with optimized structure have been implemented as individual rainfall forecasting models (IPFMs) in Seimareh subbasin of Karkheh basin, IRAN. In order to combine the IPFMs, the ordered weighted aggregation strategy (OWA) has been performed in which, two weighting methods including Orness and Orlike methods have been used and assessed for determining the weights of IPFMs. The results of this study showed that the forecasted rainfall obtained from two methods of OWA model fusion strategy has more accuracy comparing to individual forecasting models. Moreover, application of the Orlike method did a quite better job than Orness method. Besides, comparing the results of the OWA strategy methods with two other strategies viz model fusion with artificial neural network and selecting the best IPFM revealed that both Orness and Orlike methods are performing more precisely than two other strategies in forecasting rainfall.

Keywords: Model Fusion, Ordered Weighted Aggregation (OWA), Orness, Orlike, SOI, NINO 3.4

¹ Ph.D. Candidate of Water Resources Engineering, University of Tehran, Iran

² Associate Professor, University of Tehran, Iran

(*Corresponding author email address: araghinejad@ut.ac.ir)