



Comparison of Performance of Two Spatial-Temporal Approaches for Daily Rainfall Simulation Across Iran

T. Ghasdi¹, N. Ghahreman^{2*} and M. Ghamghami³

Abstract

The aim of this study is a comparison among two multi-site stochastic weather generators for simulation of winter rainfall occurrence across Iran using data of a selected network consisting of ۱۳۰ rain gauge stations with a historical data of ۲۱ years. The applied approaches included Hidden Markov Model (HMM) as a parametric approach and K-nearest neighbor (KNN) as non-parametric approach. Six stations namely, Bandar Anzali, Sari, Gharakhil Ghaemshahr, Gorgan, Shiraz and Zahedan were chosen respectively as the representative of different climates including very humid, humid, semi humid, Mediterranean, semi dry and dry climates. In comparison of first and second order momentums, results indicated that HMM performed well in almost every station. Data dispersion was examined using box plot and confidence interval analysis. The results revealed better performance for HMM. Regarding probabilities spaces, HMM showed a better performance in simulation of extreme events and higher percentiles of empirical distribution but KNN approach provided better estimations for middle percentiles values. LEPS Score index was used for comparison of cumulative distribution of observed and simulated series which showed more agreement in case of HMM. The spatial correlation was evaluated using Log-odds ratio index, which indicated that KNN model did better. Both approaches performed well in estimation of duration of wet and dry spells though a tendency to overestimate was observed at HMM and a tendency to underestimate viewed at KNN in simulating of wet spells. In general, HMM has more skill in simulation of daily rainfall series which might be attributed to its complex mathematical structure, however relatively good results of KNN approach showed that it can be recommended for less complicated applications.

Keywords: Iran, Hidden Markov, K-nearest neighbor, Daily precipitation

Received: February ۱۳, ۲۰۱۶

Accepted: March ۲۳, ۲۰۱۶

مقایسه عملکرد دو رهیافت شبیه‌سازی زمانی- مکانی بارش روزانه در گستره ایران

طاهره قصدی^۱، نوذر قهرمان^{۲*} و مهدی قمقما^۳

چکیده

در این مطالعه عملکرد دو رهیافت پارامتری مارکف پنهان (HMM) و ناپارامتری k- نزدیک‌ترین همسایه (KNN) در شبیه‌سازی سری زمانی داده‌های روزانه بارندگی زمستانه در ۱۳۰ ایستگاه باران‌سنجی ایران با طول دوره آماری ۲۱ سال مورد ارزیابی قرار گرفته است. شش ایستگاه بندرانزلی، ساری، قراخیل قائم‌شهر، گرگان، شیراز و زاهدان نیز به ترتیب به عنوان ایستگاه‌های معرف اقلیم بسیار مرطوب، مرطوب، نیمه‌مرطوب، مدیترانه‌ای، نیمه‌خشک و خشک انتخاب شده‌اند. در شبیه‌سازی گشتاورهای مرتبه ۱ و ۲ و مقایسه پراکنش داده‌ها با استفاده از دو نمودار جعبه‌ای و نمودار فاصله اطمینان ۹۵ درصد، HMM نتایج بهتری داشته، در مقایسه فضای احتمالاتی همه ایستگاه‌ها عملکرد HMM در مقادیر حدی و صدک‌های بالا، و عملکرد KNN در مقادیر میانی توزیع بهتر می‌باشد. براساس روش امتیازدهی LEPS Score و نمودارهای توزیع تجمعی تجربی نیز HMM نتایج بهتری را ارائه نموده است. در شبیه‌سازی وابستگی‌های مکانی بر اساس روش نسبت لگاریتمی بخت‌ها، عملکرد KNN بهتر بوده است. در شبیه‌سازی فراوانی روزهای تر و خشک، بیش برآوردی در HMM و کم برآوردی در KNN مشاهده می‌شود. در تداوم‌های خشک و تر هر دو مدل در شبیه‌سازی تداوم‌های کوتاه‌تر دارای بیش‌برآوردی بودند. در مجموع مهارت HMM در شبیه‌سازی سری مصنوعی بارندگی روزانه، به دلیل ساختار پیچیده ریاضی آن بیشتر بوده، اگرچه نتایج نسبتاً خوب KNN نشان داد مدل قابلیت استفاده در کاربری‌های ساده‌تر را داراست.

کلمات کلیدی: ایران، مارکف پنهان، K- نزدیک‌ترین همسایه، بارش روزانه.

تاریخ دریافت مقاله: ۹۴/۱۱/۲۴

تاریخ پذیرش مقاله: ۹۵/۱/۴

۱- M.Sc Graduate, University of Tehran, Iran

۲- Associate Professor, Dept. of Irrigation and Reclamation Engineering, University of Tehran, Iran. Email: nghahreman@ut.ac.ir

۳- Ph.D. student of Agrometeorology, University of Tehran, Iran

*- Corresponding Author

۱- دانش‌آموخته کارشناسی ارشد هواشناسی کشاورزی دانشگاه تهران.

۲- دانشیار گروه مهندسی آبیاری و آبادانی دانشگاه تهران.

۳- دانشجوی دکتری هواشناسی کشاورزی دانشگاه تهران.

*- نویسنده مسئول

۱- مقدمه

رهیافت‌های پارامتری باشند. این مولدها بر مبنای نمونه یکپارچه‌ای از مشاهدات، بدون مفروضات اولیه و تخمین پارامتر، صرفاً با بر زدن داده‌ها، سری زمانی مصنوعی متغیرها را تولید می‌کنند. راحتی ذاتی و قابلیت انتقال این مدل‌ها به مکان‌های دیگر، باعث جذابیت و کاربرد عمومی‌شان در کاربردهای هیدرولوژیکی و سایر علوم شده است (Lall and Sharma, ۱۹۹۶, Mehrtora et al. ۲۰۰۶).

مدل K- نزدیک‌ترین همسایه^۳ (Buishand and Brandsma, ۲۰۰۱) و (Rajagopalan and Lall ۱۹۹۹) مدلی ناپارامتری است که به صورت چند مکانی به تولید سری مصنوعی متغیرها پرداخته و مادامی که بازنمونه‌گیری به صورت همزمان در مکان‌های مختلف صورت گیرد، همبستگی‌های مکانی حفظ می‌شود. این روش ابتدا توسط Young (۱۹۹۴) برای شبیه‌سازی دمای کمینه و بیشینه روزانه و بارندگی به کار گرفته شد. پس از آن (Lall and Sharma ۱۹۹۶), Brandsma and Buishand (۲۰۰۱) و Mehrtora and Sharma (۲۰۰۵) در شبیه‌سازی متغیرهای هواشناسی از این روش استفاده کردند. بزرگ‌ترین مشکل روش‌های ناپارامتری عدم توانایی بازتولید مقادیری خارج از محدوده داده‌های مشاهده شده است که مدل‌های ارتقا یافته این مشکل را برطرف کرده‌اند (Sharif and Burn, ۲۰۰۴). در مقایسه مولدهای استوکاستیک هواشناسی (Mehrthora et al. ۲۰۰۶) به ارزیابی سه مولد استوکاستیک مارکف پنهان، Wilks (۱۹۹۸) و K- نزدیک‌ترین همسایه برای شبیه‌سازی همزمان الگوهای رخداد بارش در ۳۰ ایستگاه باران‌سنجی استرالیا پرداختند. همچنین (Ghamghami et al ۲۰۱۰) عملکرد مدل تک مکانی نزدیک‌ترین همسایه همراه با آشفتگی^۴ را با عملکرد مدل پارامتری LARS مقایسه کردند. بررسی مطالعات قبلی نشان داد تاکنون مطالعه جامعی در خصوص مقایسه دو روش ذکر شده در ایران صورت نگرفته است، لذا این تحقیق با هدف ارزیابی دو رهیافت پارامتری مارکف پنهان و ناپارامتری نزدیک‌ترین همسایه در شبیه‌سازی زمانی- مکانی الگوهای بارش در کل کشور به انجام رسیده است.

شبیه‌سازی فضایی بارندگی^۵، مدل‌سازی بارندگی به صورت همزمان در ایستگاه‌های مختلف جهت حفظ همبستگی‌های مکانی و بالا بردن دقت تولید مقادیر بارندگی می‌باشد. اگرچه شبیه‌سازی وقوع و مقدار بارندگی به صورت تک‌مکانی در ایران انجام می‌شود، اما به دلیل تفاوت زیاد توزیع مکانی و زمانی بارش، تحلیل نقطه‌ای کافی نبوده و به همین دلیل منطقه‌ای کردن مدل‌سازی بارندگی از اهمیت

داده‌های هواشناسی یکی از مهم‌ترین ورودی‌های مدل‌های ریاضی هیدرولوژی، کشاورزی، اکولوژی و حفاظت آب و خاک می‌باشند، با این وجود اغلب بروز مشکلاتی از قبیل طول ناکافی سری‌های ثبت شده، عدم تایید صحت و یا عدم ثبت داده‌ها منجر به بروز پاره‌ای مشکلات و در نهایت گسترش استفاده از روش‌هایی جهت مدل‌سازی و توان پیش‌بینی داده‌ها شده است. مولدهای استوکاستیک هواشناسی^۱ مدل‌های آماری‌ای هستند که با هدف شبیه‌سازی سریع و واقع‌گرایانه سری‌های تصادفی متغیرهای جوی مانند دما، بارندگی و سرعت باد به کار می‌روند (Wilks and Wilby ۱۹۹۹). این مدل‌ها در مقیاس‌های کوچک مکانی به تولید سریع و تصادفی داده‌ها با طول مورد نظر کاربر می‌پردازند، به طوری که سری زمانی تولید شده، مشخصه‌های آماری توزیع سری مشاهداتی را داراست. استفاده از مولدهای تک مکانی به دلیل عدم تاثیرپذیری از دیگر مکان‌ها در شبیه‌سازی، قادر به بازتولید مناسب همبستگی‌های قوی مکانی موجود بین متغیرهای مختلف هواشناسی نمی‌باشند. این مسئله در موقعیت‌هایی که نیاز به اطلاعات همزمان متغیرهای هواشناسی در مکان‌های مختلف مانند مطالعات هیدرولوژیکی و یا دبی رودخانه و سیلاب وجود دارد، موجب بروز مشکلاتی خواهد شد. این امر موجب گسترش استفاده از مولدهای چندمکانی شده است. مدل مارکف پنهان^۲ از انواع مهم مدل‌های پارامتری است. این مدل‌ها، با برآزش یک تابع توزیع آماری مستقل یا شرطی خاص بر داده‌های مشاهداتی به شبیه‌سازی سری زمانی داده‌ها می‌پردازند. (Hughes and Guttorp ۱۹۹۴) برای اولین بار جهت پیش‌بینی رخدادهای بارندگی روزانه از مدل مارکف پنهان استفاده کردند. (Zucchini and Guttorp ۱۹۹۱), Thyer and Kuczera (۲۰۰۰), Robertson et al. (۲۰۰۴), Ailliot et al. (۲۰۰۸), Maruddani et al. (۲۰۱۰) و بسیاری دیگر از محققان نیز با استفاده از مدل مارکف پنهان به شبیه‌سازی متغیرهای مختلف جوی پرداخته‌اند. (Ghamghami et al. ۲۰۱۵) در مدل‌سازی مکانی- زمانی وقوع و مقدار بارش زمستانه در گستره ایران با استفاده از داده‌های بارندگی روزانه ۲۱ سال (۱۹۹۰-۲۰۱۰) مربوط به ۱۳۰ ایستگاه باران‌سنجی به شبیه‌سازی تصادفی وقوع و مقدار بارش به صورت همزمان توسط روش مارکف پنهان پرداختند. نیاز به مفروضات اولیه، عدم بازتولید مناسب وابستگی‌های زمانی و مکانی، تخمین پارامترها و عدم انتقال راحت به دیگر مکان‌ها از جمله مشکلات مولدهای پارامتری است (Sharif and Burn, ۲۰۰۶). مولدهای وضع هوای ناپارامتری، در صورت وجود تعداد داده کافی می‌توانند جایگزین مناسبی برای

مدل‌های مبتنی بر کار ایشان، حالات جوی روزانه بارش به صورت توالی‌های قابل مشاهده یا پیوسته (سری زمانی مقادیر) و یا گسسته (سری زمانی وقوع و عدم وقوع بارش) در نظر گرفته می‌شود. حالات جوی نیز توالی‌های پنهان را تشکیل می‌دهند که واژه "پنهان" به غیر قابل مشاهده بودن حالت جوی اشاره دارد. منظور از حالت جوی در یک روز معین، الگوی خاصی است که کل کشور را تحت تاثیر قرار داده و وقوع یا عدم وقوع بارندگی در ایستگاه‌های مختلف با احتمالات متفاوت بستگی به آن دارد. در صورت درست بودن کارکرد مدل مارکف، الگوهای بدست آمده می‌توانند به صورت یک الگوی سینوپتیکی تفسیر شوند. اگر $S = \{S_n, n = 1, 2, \dots\}$ را یک فرآیند تصادفی مارکف در نظر بگیریم و $\Omega = \{\Omega_k, K = 1, 2, \dots\}$ تابعی از S باشد که از طریق Ω مشاهده می‌شود می‌توان نوشت: $\Omega_k = f(S_k)$. بنابراین می‌توان گفت S یک فرآیند حالت پنهان و Ω فرآیند مشاهده است. مدل مارکف پنهان با $(S, \Omega, P, \Phi, \pi)$ تعریف شده - که در آن: $S = \{s_1, \dots, s_N\}$: مجموعه حالات، $\Omega = \{\Omega_1, \dots, \Omega_M\}$: مجموعه مشاهدات. $P = \{p_{ij}\}$: مجموعه احتمالات انتقال حالت که p_{ij} احتمال انتقال سیستم از حالت s_i به s_j ، $\Phi = \{\Phi_i(o_k)\}$: احتمالات مشاهدات و $\Phi_i(o_k)$ احتمال انتشار o_k وقتی سیستم در حالت s_i است و $\pi = \{\pi_i\}$ احتمالات حالت ابتدایی می‌باشد. اگر مقدار بارندگی در روز t در ایستگاه k باشد، در این صورت با رابطه $Y_t = (Y_t^1, \dots, Y_t^K)$ که $K=130$ بردار مقدار بارندگی در روز t بدست می‌آید. برای دستیابی به الگوی فضایی بارش در هر مرحله اجرای مدل باید از بردار Y_t به عنوان یک عدد استفاده کرد. هر بردار Y_t یک عنصر در توالی مشاهدات یک حالت جوی متعلق به توالی پنهان S_t که $S_t \in M$ است.

ویژه‌ای برخوردار است. در این پژوهش با هدف شبیه‌سازی مکانی - زمانی داده‌های روزانه بارندگی و دستیابی به الگوهای سینوپتیکی حاکم بر بارش‌های زمستانه به ارزیابی عملکرد دو رهیافت پارامتری مارکف پنهان (Ailliot et al. (۲۰۰۸) و رهیافت ناپارامتری نزدیک-ترین همسایه (Buishand and Lall and Sharma (۱۹۹۶) و Brandsma (۲۰۰۱) پرداخته شده است.

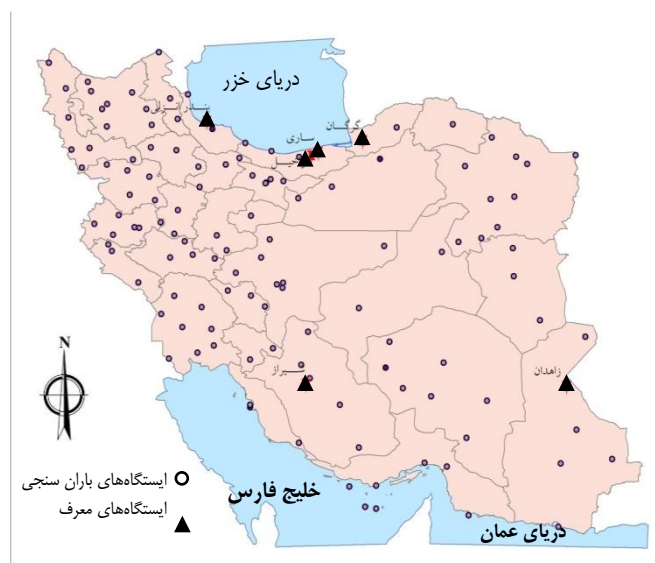
۲- مواد و روش‌ها

۲-۱- توصیف منطقه و داده‌ها

در این مطالعه، از داده‌های روزانه ۱۳۰ ایستگاه باران‌سنجی (شکل ۱) شامل ۲۱ سری زمانی مستقل زمستانه بارندگی طی دوره آماری (۲۰۱۰-۱۹۹۰) و بدون خلأ آماری (رفع خلأهای آماری در پژوهش‌های پیشین) استفاده شده است. برای مقایسه نتایج ابتدا سری زمانی معادل ۱۰۰ سال با تکرار ۱۰ بار توسط هر دو مدل شبیه‌سازی شده و میانگین پارامترهای این ۱۰ سری، مورد مقایسه قرار گرفته است. با توجه به تعداد زیاد ایستگاه‌ها و جهت دستیابی به نتایج اقلیمی دقیق‌تر، ایستگاه‌های معرف بندرانزلی، ساری، قراخیل قائم‌شهر، گرگان، شیراز و زاهدان به ترتیب به عنوان معرف اقلیم بسیار مرطوب، مرطوب، نیمه‌مرطوب، مدیترانه‌ای، نیمه خشک و خشک در کنار نتایج کلی ۱۳۰ ایستگاه بررسی شده‌اند.

۲-۲- مدل مارکف پنهان (HMM)

مدل مارکف پنهان توسط Rabiner (۱۹۸۶) ارائه شده و پس از آن Hughes and Guttorp (۱۹۹۴) از این مدل جهت شبیه‌سازی الگوهای فضایی و زمانی وقوع و مقدار بارندگی استفاده کردند. در



شکل ۱- نقشه پراکنندگی ایستگاه‌های باران‌سنجی مورد استفاده

در روابط (۴) متغیر W دارای توزیع نرمال بوده و $\beta^{(s)}$ یک توان مثبت به ازای حالت جوی s است. رابطه فوق توسط $\beta^{(s)}$ از یک بردار چند متغیره نرمال به یک بردار تصادفی با توزیع چند متغیره ترکیبی (پیوسته - گسسته) تبدیل می‌شود. اگر $W_t = (W_t(1), \dots, W_t(K))$ بردار مکانی ایستگاه‌ها باشد، آنگاه:

$$W_t = m^{(s)} + H^{(s)} Z_t, \quad (s=1, \dots, M) \quad (5)$$

در رابطه (۵)، Z برداری با متغیرهای تصادفی نرمال استاندارد، m و H به ترتیب بردار K بعدی میانگین و انحراف معیار به ازای هر حالت معین s هستند. بنابراین ابتدا می‌بایست بردارهای K بعدی میانگین و انحراف معیار و پارامتر β به ازای حالت معین s برآورد شده و سپس با تولید تصادفی، ابتدا توالی حالات پنهان شبیه‌سازی و سپس بردارهای W و Y به ازای حالت معین شبیه‌سازی شوند. اگر $\theta = (\theta^{(1)}, \dots, \theta^{(M)})$ مجموعه پارامترهای مدل باشد و $\theta^{(s)}$ شامل احتمالات اولیه برای شرایط مرزی و احتمالات انتقال برای سایر عناصر توالی پنهان، در این صورت هدف از آموزش مدل، برآورد بهینه پارامترهای θ است. پارامترهای $\theta^{(s)}$ که $s=(a, \dots, M)$ مجموعه‌ای از پارامترهای $\beta^{(s)}, H^{(s)}, m^{(s)}$ و ماتریس احتمالات انتشار $P(Y_t|S_t = s)$ است که از الگوریتم EM برای برآورد این مجموعه پارامترها استفاده می‌شود. الگوریتم EM شامل دو مرحله است و در ابتدا به صورت تصادفی مقادیر اولیه‌ای را برای پارامترها در نظر می‌گیرد:

۱- E-step: امیدریاضی تابع درستنمایی با فرض وجود پارامترهای مرحله قبل (θ_n) و داده‌های مشاهده شده (o) محاسبه می‌شود.

$$Q(\theta|\theta_n) = E_{q|o, \theta_n}[\log L(\theta: o, q)] \quad (6)$$

۲- M-step: در این مرحله الگوریتم با بیشینه‌سازی تابع Q که از مرحله قبل به دست آمده است، به برآورد پارامترها می‌پردازد.

$$\theta_{n+1} = \arg_{\theta} \max Q(\theta|\theta_n) \quad (7)$$

دو مرحله‌ی فوق تا رسیدن به همگرایی به صورت متناوب تکرار شده، مقدار تابع درست‌نمایی با هر بار تکرار این مرحله افزایش یافته و نهایتاً به یک مقدار بیشینه نسبی همگرا می‌شود (Ejlali and Pezeshk ۲۰۰۹).

۲-۳- مدل K- نزدیک‌ترین همسایه

الگوریتم K- نزدیک‌ترین همسایه شامل انتخاب روزهایی از میان داده‌های تاریخی است که از نظر مشخصات به روز مورد نظر نزدیک

مدل مارکف پنهان دارای دو فرض اساسی جهت ساده‌سازی است (Ailliot et al. ۲۰۰۸):

۱- الگوهای جوی وابستگی‌های پیاپی مرتبه یک دارند که ماتریس‌های احتمال انتقال از محاسبات آنها به دست می‌آید.

$$P(S_t|S_1, \dots, S_{t-1}, Y_1, \dots, Y_{t-1}) = P(S_t|S_{t-1}) \quad (1)$$

۲- بارش در یک روز معین تنها به حالت جوی همان روز وابسته است که از محاسبات این فرض، ماتریس‌های احتمال انتشار به دست می‌آید.

$$P(Y_t|Y_1, \dots, Y_{t-1}, S_1, \dots, S_{t-1}) = P(Y_t|S_t) \quad (2)$$

از هر دو فرض فوق می‌توان نتیجه گرفت داده‌های بارندگی در هر ایستگاه مستقل از ایستگاه‌های دیگر بوده و وابستگی‌های فضایی به ازاء یک حالت معین جوی مدل‌سازی می‌شوند:

$$P(Y_t|S_t) = \prod_{k=1}^K P(Y_t^k|S_t) \quad (3)$$

بردار احتمالات اولیه نیز می‌بایست برای مدل‌سازی در نظر گرفته شود. با توجه به عدم آگاهی از توالی حالات پنهان، مجهولات بسیاری مانند ماتریس احتمالات انتقال، ماتریس احتمالات انتشار و ماتریس احتمالات اولیه در مدل‌سازی مارکف پنهان وجود دارند و چون حل تحلیلی آنها میسر نیست، می‌بایست از روش‌های برآورد نظیر الگوریتم پارامتر یا الگوریتم آموزش استفاده کرد، بدین صورت که به ازاء تعداد حالات متفاوت، مدل آموزش دیده و با معیار BIC بهترین مدل جهت رسیدن به اهداف بعدی انتخاب می‌شود. رهیافت به کار رفته در این مطالعه مبتنی بر کار (Ailliot et al. ۲۰۰۸) است که در آن با یک تبدیل توانی^۶ ماهیت گسسته - پیوسته بودن داده‌های بارش را مدیریت کرده و به طور همزمان به شبیه‌سازی تصادفی وقوع و مقدار بارندگی می‌پردازد. در رهیافت‌هایی که سایر محققین بدان پرداخته‌اند، ابتدا متغیر گسسته که همان وقوع یا عدم وقوع بارندگی است، شبیه‌سازی شده و سپس مقادیر بارندگی در صورت وقوع تولید می‌شود. در روش ارائه شده توسط Ailliot et al. (۲۰۰۸) این مسئله توسط یک توزیع چندمتغیره نرمال رفع شده است. یعنی اگر $S_t = s$ در نظر بگیریم آنگاه:

$$X_t(k) = \begin{cases} W_t(k) & , (W_t(k) \leq 0) \\ W_t(k)\beta^{(s)}(k) & , (W_t(k) > 0) \end{cases} \quad (4)$$

$$Y_t(k) = \max(X_t(k), 0)$$

بردار اخیر به عنوان بردار وضعیت جدید در نظر گرفته شده و مراحل تا رسیدن به طول کافی سری مصنوعی، ادامه می‌یابد. تمامی مراحل کار در محیط فرترن کدنویسی شده‌اند.

۳- نتایج و بحث

۳-۱- آموزش مدل مارکف

جهت اجرای مدل مارکف پنهان، ابتدا پارامترهای مدل به ازاء تعداد حالات $M = 1, \dots, 9$ برآورد شد که تعداد هشت حالت دارای کمترین BIC بوده است (جدول ۱). وجود هشت حالت مختلف جوی نشان دهنده احتمالات متفاوت وقوع باران و بیانگر تنوع الگوهای بارش زمستانه می‌باشد. در شکل ۲ دایره‌های موجود بر هر نقطه نشان دهنده میزان احتمال وقوع بارندگی به ازای حالت معینی از جو است. هرچه قطر این دوایر بیشتر باشد، احتمال رخداد بارندگی بیشتر است، به طور مثال الگوهای چهار و شش نشان‌دهنده شرایط خشکسالی (پایداری) و الگوهای سه و پنج نشان‌دهنده شرایط ناپایداری (ترسالی) در اکثر نقاط کشور می‌باشند، اما در شکل دو شرایط ترسالی (ناپایداری) تنها در منطقه شمال غرب دیده می‌شود. انتظار می‌رود هر یک از این هشت الگو، منطبق بر یک الگوی خاص سینوپتیکی باشند. الگوهای سینوپتیکی بارش زمستانه در ایران بر مبنای مطالعه Hejazi Zadeh and Fattahi (۲۰۰۴) مشتمل بر هشت الگوی کم فشار اروپای شمالی، پرفشار مرکزی، پرفشار سیبری، پرفشار اروپای شرقی، پرفشار اروپای شمالی، پرفشار شرقی، کم فشار مدیترانه‌ای و تلفیق پرفشار سیبری و اروپاست.

۳-۲- نتایج

۳-۲-۱- مقایسه‌ی میانگین‌ها و انحراف معیارهای فصلی

برای بررسی میزان معنی‌داری اختلافات بین میانگین‌ها و انحراف معیارها با استفاده از آزمون‌های F و t و در سطح ۹۵٪ در ایستگاه‌های معرف، نتایج (جدول ۲) نشان داد مدل KNN در شبیه‌سازی میانگین فصلی تمام ایستگاه‌ها به جز دو ایستگاه گرگان و زاهدان موفق بوده و مدل HMM میانگین فصلی همه ایستگاه‌ها را به خوبی شبیه‌سازی کرده است. در شبیه‌سازی انحراف معیارهای فصلی مدل KNN در همه ایستگاه‌ها به استثنای ایستگاه زاهدان و مدل HMM در شبیه‌سازی انحراف معیار تمام ایستگاه‌ها به خوبی عمل کرده است.

نتایج مقایسه میانگین و انحراف معیار فصلی تمام ایستگاه‌ها با استفاده از نمودار ۱:۱ (شکل ۳) نشان داد مدل HMM عملکرد بهتری داشته و مدل KNN میانگین فصلی تعدادی از ایستگاه‌ها را

می‌باشند، به طوری که یکی از این روزها به صورت تصادفی برای شبیه‌سازی روز متعاقب روز انتخابی باز نمونه‌گیری می‌شود. در این رهیافت نمونه‌گیری همزمان همراه با جایگزینی انجام می‌شود که به آن خودگردان‌سازی^۷ می‌گویند. فرض شود بردار اولیه‌ای در سری ساختگی وجود دارد که به آن بردار وضعیت گفته می‌شود، در این صورت هدف شبیه‌سازی برداری است که پس از رخداد بردار وضعیت، تحقق می‌یابد و بردار خلف بردار وضعیت نامیده می‌شود. در الگوریتم شبیه‌سازی ابتدا ماتریس داده‌های بارندگی $(n \times p)$ فراخوانی شده و با تعیین عرض پنجره متحرک جهت انتخاب همسایگان (L) ، ماتریس همسایگان با ابعاد $(L \times P)$ تشکیل می‌شود. سپس ماتریس کوواریانس ماتریس همسایگان (C_t) محاسبه شده و با انتخاب یک روز معین جهت تشکیل بردار وضعیت (X_t) برای شروع شبیه‌سازی، فاصله بین دو بردار همسایه و بردار وضعیت بر اساس فاصله ماهالانبیس محاسبه می‌شود.

$$D_m = \sqrt{(X_t - X_m) C_t^{-1} (X_t - X_m)^T} \quad (8)$$

X_m و X_t بردارهای وضعیت و همسایگان و $L : m = 1$

پس از صعودی نمودن فواصل و تعیین k تعداد از نزدیک‌ترین بردارها با رابطه $K = \sqrt{L}$ (Rajagopalan and Lall, ۱۹۹۹)، توزیع احتمالاتی گسسته‌ای بر همسایگان برآزش داده می‌شود به طوری که به همسایه‌های نزدیک‌تر وزن بیشتری بدهد، سپس مقدار توزیع تجمعی از رابطه (۹) برآورد می‌شود:

$$P_j = \sum_{l=1}^j w_l, \quad w_l = \frac{1/j}{\sum_{l=1}^k 1/j} \quad (9)$$

با تولید عدد تصادفی $(0 < r < 1)$ ، روز متعاقب روز متناظر با d_i در صورتی که r به P_i نزدیک باشد، به عنوان بردار روز خلف در نظر گرفته می‌شود. جهت تولید مقادیر جدید در سری شبیه‌سازی شده، یک توزیع تخمینگر کرنل شامل تخمین انحراف معیار شرطی (σ) و عرض باند (λ) بر همسایگان برآزش داده شده و با تولید متغیر تصادفی Z_{t+1} از توزیع نرمال استاندارد، مقدار جدید از رابطه (۱۰) محاسبه می‌گردد:

$$Y_{t+1} = X_{t+1} + \lambda \sigma Z_{t+1} \quad (10)$$

از آنجا که امکان دارد مراحل فوق منجر به تولید مقادیر منفی شود، با تعریف یک مقدار احتمال آستانه‌ای (α) با روش سعی و خطا، و تغییر مقدار پارامتر عرض باند، احتمال وقوع مقادیر منفی به حداقل می‌رسد.

$$\lambda = -X_{t+1} / (Z_{\alpha} * \sigma) \quad (11)$$

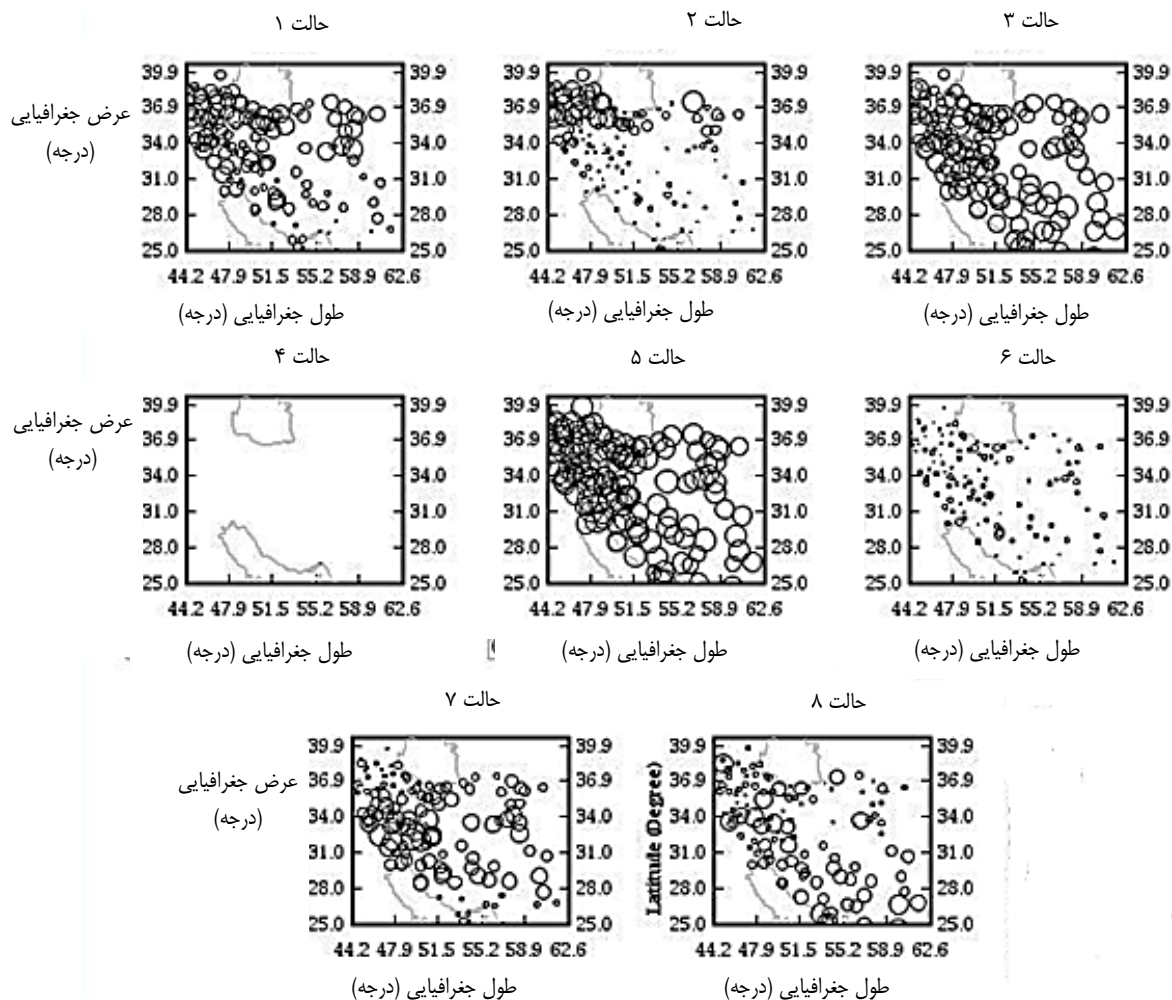
که عموماً میانگین بارش فصلی زیر ۳۰۰ میلیمتر داشته‌اند، کم برآورد کرده است. در مورد انحراف معیار فصلی نیز در هر دو مدل پراکندگی اطراف خط ۱:۱ بیشتر شده که این امر برای مدل KNN بسیار بیشتر از HMM می‌باشد.

جدول ۱- معیار BIC جهت انتخاب تعداد حالات جوی بهینه

BIC	تعداد حالات
۶۷۷۸۸۳/۱	۱
۶۰۹۳۱۶/۳	۲
۵۸۹۰۶۴/۱	۳
۵۷۸۶۲۸/۵	۴
۵۶۹۱۰۸/۷	۵
۵۷۰۲۲۳/۵	۶
۵۶۹۱۰۸/۸	۷
۵۶۸۷۹۰/۹	۸
۵۶۹۴۹۳/۹	۹

۳-۲-۲- مقایسه دامنه تغییرات

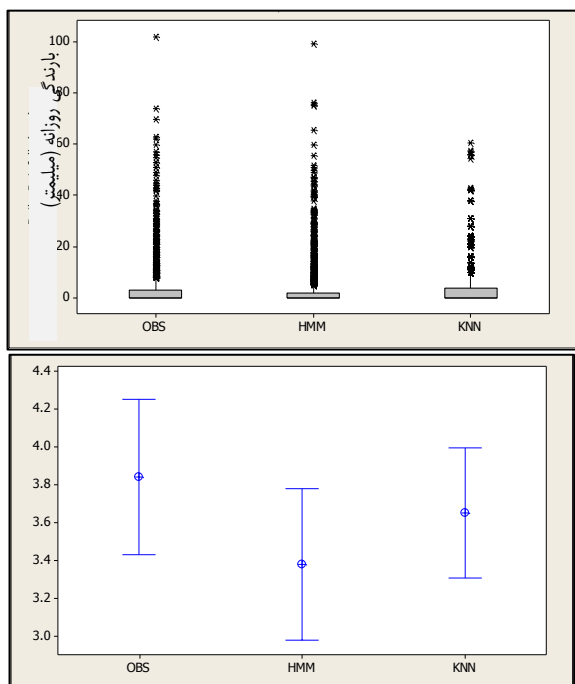
برای مقایسه چگونگی پراکنش داده‌های شبیه‌سازی شده و مشاهداتی در حدود اعتماد ۹۵ از نمودار جعبه‌ای استفاده شده است. در ایستگاه بندرانزلی (شکل ۴)، مدل HMM به خوبی توانسته است دامنه کلی تغییرات و بزرگترین مقدار را شبیه‌سازی نماید، اما مدل KNN در شبیه‌سازی بزرگترین رخداد بارندگی روزانه ناتوان بوده ولی دامنه تغییرات ۹۵ درصد را بهتر شبیه‌سازی کرده است. در ایستگاه ساری (شکل ۵) مدل HMM در شبیه‌سازی دامنه تغییرات کلی بارش موفق‌تر از مدل KNN بوده، اما شبیه‌سازی مدل KNN در بزرگترین رخداد حدی تفاوت معنی‌داری با داده‌های مشاهده شده دارد.



شکل ۲- الگوهای توزیع احتمالات بارندگی در ۱۳۰ ایستگاه بر مبنای مدل HMM

جدول ۲- آزمون‌های مقایسه مقادیر میانگین و انحراف معیار

زاهدان		شیراز		گرگان		قراخیل		ساری		بندرانزلی			
KNN	HMM	KNN	HMM	KNN	HMM	KNN	HMM	KNN	HMM	KNN	HMM	مدل	
۰	۰/۹۹۲	۰/۰۹۴	۰/۳۳۱	۰/۰۰۱	۰/۳۴	۰/۷۴۳	۰/۰۴۶	۰/۰۱۳	۰/۳۲۶	۰/۴۸۶	۰/۱۱۸	P-value	آزمون t
۰	۰/۹۵۳	۰/۷۰۶	۰/۹۷۶	۰/۳۴۱	۰/۰۱۱	۰/۶۹۴	۰/۵۴۷	۰/۸۳	۰/۸۶	۰/۹۴۸	۰/۹۲۹	P-value	آزمون F



شکل ۴- نمودار جعبه‌ای و فاصله اطمینان ۹۵٪ ایستگاه بندرانزلی

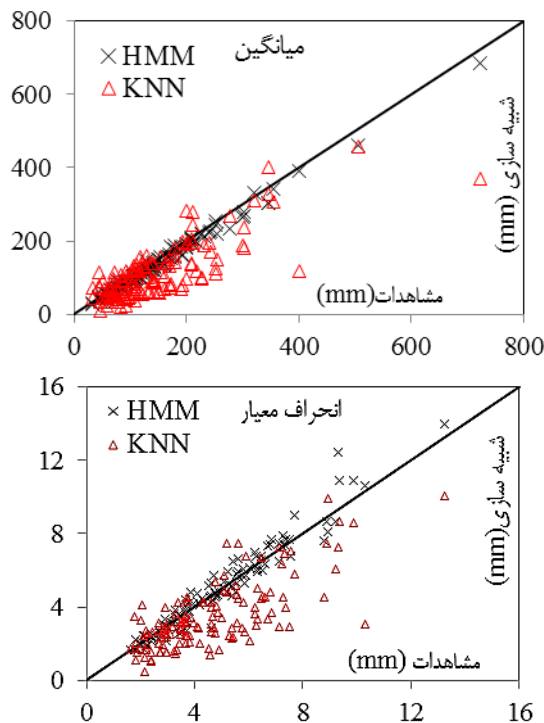
در مورد فاصله اطمینان، مدل HMM با هم‌پوشانی قابل توجه دامنه میانی تغییرات، عملکرد موفق‌تری نسبت به KNN دارد. در ایستگاه زاهدان (شکل ۹) با توجه به فراوانی زیاد مقادیر صفر، نمودار جعبه‌ای برای هر سه مجموعه به صورت یک خط صاف و صفر نمایش داده شده است. طبق نمودار فاصله اطمینان، خروجی HMM منطبق و خروجی KNN خارج از محدوده داده‌های مشاهده شده می‌باشد.

۳-۲-۳- مقایسه فضای احتمالاتی

در مقایسه توابع توزیع تجمی تجربی داده‌های شبیه‌سازی شده و مشاهداتی، در ایستگاه بندرانزلی (شکل ۱۰) مدل KNN در مقادیر میانی توزیع بهتر عمل کرده، با این وجود HMM نیز دارای برازش خوبی در میانه توزیع است. در ایستگاه ساری (شکل ۱۱) توابع


همچنین HMM در شبیه‌سازی فاصله اطمینان ۹۵ درصد بهتر از مدل KNN عمل کرده است. در ایستگاه قراخیل قائم‌شهر (شکل ۶) اما مدل HMM در شبیه‌سازی رخداد حدی بیش برآوردی دارد اما KNN به خوبی توانسته دامنه کلی تغییرات را شبیه‌سازی کند و عملکرد بهتری در شبیه‌سازی فاصله اطمینان ۹۵ درصد دارد.

در ایستگاه گرگان (شکل ۷) هر دو مدل در شبیه‌سازی رخدادهای حدی دچار کم برآوردی هستند که این کم برآوردی برای مدل KNN بیشتر می‌باشد. در شبیه‌سازی فاصله اطمینان ۹۵ درصد خروجی مدل KNN هیچ‌گونه هم‌پوشانی‌ای با دامنه تغییرات مشاهده شده ندارد اما HMM به خوبی دامنه میانی تغییرات را شبیه‌سازی کرده است. در ایستگاه شیراز (شکل ۸) HMM و KNN رخداد حدی را به ترتیب بزرگ‌تر و کوچک‌تر از واقعیت شبیه‌سازی کرده‌اند.






شکل ۳- نمودار ۱:۱ میانگین‌ها و انحراف معیارها


شکل ۶- نمودار جعبه‌ای و فاصله اطمینان ۹۵٪ ایستگاه قراخیل قائم شهر






HMM و مشاهداتی برآزش خوبی بر هم دارند اما مدل KNN قادر به شبیه‌سازی احتمالات بزرگتر از ۹۴٪ نمی‌باشد.




شکل ۷- نمودار جعبه‌ای و فاصله اطمینان ۹۵٪ ایستگاه گرگان




شکل ۵- نمودار جعبه‌ای و فاصله اطمینان ۹۵٪ ایستگاه ساری






شکل ۸- نمودار جعبه‌ای و فاصله اطمینان ۹۵٪ ایستگاه شیراز




شکل ۱۰- توزیع تجمعی تجربی داده‌ها، بندرانزلی



شکل ۹- نمودار جعبه‌ای و فاصله اطمینان ۹۵٪ ایستگاه زاهدان

شکل ۱۱- توزیع تجمعی تجربی داده‌ها، ساری



در ایستگاه قراخیل قائم‌شهر (شکل ۱۲) خروجی KNN برازش خوبی با داده‌های مشاهده شده دارد. اما تابع توزیع تجمعی تجربی مدل HMM در مقادیر بزرگتر از مقادیر مشاهده شده به مقدار یک می‌رسد. در دو ایستگاه گرگان و شیراز (شکل‌های ۱۳ و ۱۴) نتایج مشابه نتایج دو ایستگاه قبل به‌دست آمده است. در ایستگاه زاهدان (شکل ۱۵) مدل HMM نتیجه بسیار قابل قبولی در فضای احتمالاتی دارد، ولی KNN بیش برآوردی قابل توجهی دارد.

شکل ۱۲- توزیع تجمعی تجربی داده‌ها، قراخیل قائمشهر


برای بررسی کمی میزان انطباق توابع توزیع تجمعی داده‌های مشاهده شده و شبیه‌سازی شده، از روش امتیازدهی LEPS Score استفاده شد که بیانگر میزان خطای خطی در فضای احتمالاتی است. با توجه به اینکه توزیع تجربی یک توزیع گسسته است، در اینجا از تابع توزیع گاما جهت برازش بر داده‌های بارندگی روزانه طی فصل زمستان استفاده شده است. مطابق جدول ۳ مدل HMM در همه ایستگاه به جز قراخیل قائم‌شهر دارای مهارت کلی بیشتری نسبت به مدل KNN می‌باشد. محاسبه فراوانی نسبی SK در تمام ایستگاه‌ها مطابق شکل ۱۶ نشان داد بیشترین فراوانی KNN و HMM مربوط به طبقات ۸۰-۷۰ و ۹۰-۸۰ بوده که حکایت از برتری HMM در شبیه‌سازی فضای احتمالاتی حاکم بر داده‌های واقعی در اکثر ایستگاه‌ها دارد.

۳-۲-۴- همبستگی‌های مکانی

برای مقایسه توانمندی مدل‌ها در ساخت وابستگی‌های مکانی وقوع و عدم وقوع بارش از آماره نسبت لگاریتمی بخت‌ها^۱ استفاده شده است (Mehrtora (۲۰۰۶).


جدول ۳- مهارت دو مدل براساس امتیازدهی LEPS Score

KNN	HMM	
۷۵/۴۷	۸۹/۶۸	بندرانزلی
۷۳/۹۴	۹۳/۱۱	ساری
۸۷/۶۲	۸۱/۵۵	قراخیل
۶۶/۴۸	۹۵/۲۳	گرگان
۷۶/۸۴	۸۷/۹۵	شیراز
۵۸/۳۲	۹۶/۱۲	زاهدان




شکل ۱۶- فراوانی نسبی طبقات SK مربوط به ۱۳۰ ایستگاه


$$lr_{i,j} = \log \frac{P_{i,j}^+ P_{i,j}^-}{P_{i,j}^- P_{i,j}^+} \quad (14)$$



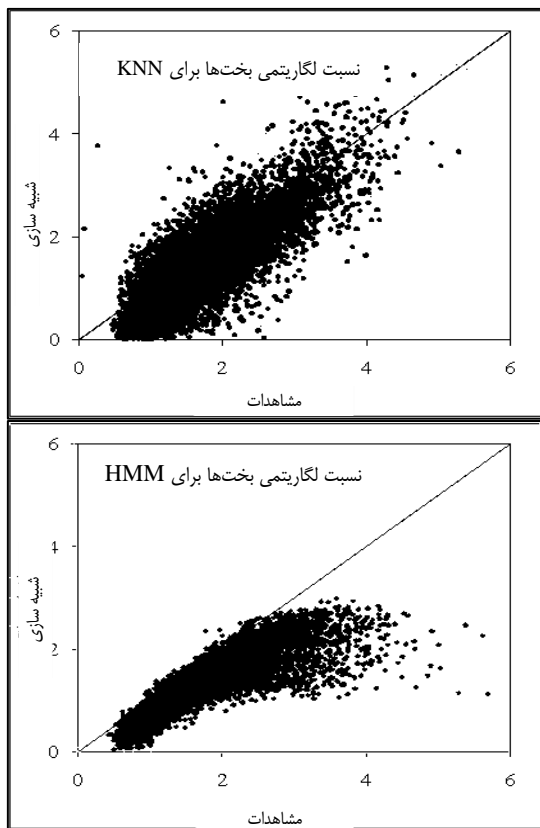
شکل ۱۳- مقایسه توزیع تجمعی تجربی داده‌ها، گرگان




شکل ۱۴- مقایسه توزیع تجمعی تجربی داده‌ها، شیراز



شکل ۱۵- مقایسه توزیع تجمعی تجربی داده‌ها، زاهدان



شکل ۱۷- نسبت لگاریتمی بخت‌ها بین هر جفت ایستگاه



شکل ۱۸- فراوانی نسبی روزهای تر و خشک



در این رابطه، $ln_{i,j}$ نسبت مذکور بین دو ایستگاه i و j ($i \neq j$) است. $P_{i,j}^1, P_{i,j}^2, P_{i,j}^3, P_{i,j}^4$ احتمالات توأم وقوع یا عدم وقوع بارش در ایستگاه i و j است. هرچه مقدار این نسبت بزرگتر باشد، نشان از وابستگی بیشتر بین دو ایستگاه دارد. براساس نمودارهای شکل ۱۷ مدل HMM قادر به شبیه‌سازی وابستگی‌ها یا نسبت لگاریتمی بخت بزرگتر از ۲ و ۳ نمی‌باشد و در این زمینه دارای کم برآوردی است. پراکندگی نقاط در اطراف خط ۱:۱ برای مدل KNN بیشتر است و مدل قادر به شبیه‌سازی وابستگی‌های زیاد حتی بیش از ۴ نیز می‌باشد.

۳-۲-۵- فراوانی تداوم‌های تر و خشک

فراوانی نسبی دوره‌های تر (دارای بارندگی بیشتر از ۲/۵۴ میلی‌متر) و دوره‌های خشک (دارای بارندگی کمتر از ۲/۵۴ میلی‌متر) برای شش ایستگاه منتخب در شکل ۱۸ آورده شده است. فراوانی‌های مشاهده شده و شبیه‌سازی شده از هر دو مدل تفاوت معنی‌داری با هم ندارند و هر دو مدل در این زمینه توانمند بوده‌اند. در بررسی فراوانی روزهای خشک نیز اختلاف معنی‌داری در همه ایستگاه‌های منتخب بین فراوانی روزهای خشک مشاهده شده و شبیه‌سازی شده به چشم نمی‌خورد. در شکل‌های ۱۹ تا ۲۴ فراوانی نسبی تداوم‌های یک تا ۱۲ روزه تر و خشک به دست آمده از خروجی هر دو مدل با داده‌های مشاهده‌ای مقایسه شده‌اند. در همه این ایستگاه‌ها بیش برآوردی فراوانی تداوم‌های کمتر، در هر دو حالت خشک و تر منجر به کم برآوردی فراوانی تداوم‌های بزرگتر شده‌اند که این نتیجه برای هر کدام از مدل‌ها با شدت و ضعف روبرو است و در مجموع مدل HMM دارای عملکرد بهتری است.



۴- نتیجه‌گیری و پیشنهادها

در این پژوهش به مقایسه نتایج شبیه‌سازی فضایی بارندگی روزانه زمستانه برای یک دوره صد ساله با استفاده از داده‌های بارندگی روزانه ۱۳۰ ایستگاه باران‌سنجی در گستره کشور طی سال‌های ۱۹۹۰-۲۰۱۰ با دو روش استوکاستیک پارامتری و ناپارامتری مارکف پنهان و K- نزدیک‌ترین همسایه پرداخته شد.



شکل ۱۹- فراوانی نسبی تداوم‌های تر و خشک بندرانزلی

شکل ۲۰- فراوانی نسبی تداوم‌های تر و خشک ساری




شکل ۲۱- فراوانی نسبی تداوم‌های تر و خشک قراخیل قائمشهر


شکل ۲۲- فراوانی نسبی تداوم‌های تر و خشک گرگان

شکل ۲۳- فراوانی نسبی تداوم‌های تر و خشک زاهدان

بر مبنای سهولت استفاده و نیز زمان مورد نیاز در شبیه‌سازی، و نیز حفظ همبستگی‌های مکانی به دلیل شبیه‌سازی‌های برداری و بازنمونه‌گیری همراه با جایگزینی، مدل نزدیک‌ترین همسایه انتخاب بهتری است، اما با وجود استفاده از توزیع کرنل در شبیه‌سازی داده‌ها، مدل KNN نه تنها توان تولید مقایر جدید در سری شبیه‌سازی شده را نداشت بلکه در بسیاری از ایستگاه‌ها، قادر به بازتولید مقادیر حدی نیز نبود، اما در بازتولید مقادیر میانی توزیع تجمعی تجربی، در بسیاری از ایستگاه‌ها عملکرد بهتری نسبت به HMM داشت. مدل HMM در صورت وجود تعداد حالت‌های جوی بهینه، قادر به بازتولید همبستگی‌های زمانی کوتاه مدت بوده و همچنین ساختار استفاده از آماره نسبت لگاریتمی بخت‌ها هم چنین نتیجه‌ای مشاهده شد. همچنین مدل HMM در شبیه‌سازی گشتاورهای مرتبه ۱ و ۲ سری زمانی بارش طبق آزمون‌های آماری و نمودارهای ۱:۱، در بازتولید مقادیر حدی و صدک‌های بالای سری زمانی بارش، و مقایسه نمودارهای توزیع تجمعی تجربی بر اساس روش امتیاز دهی LEPS Score دارای عملکرد بهتری بوده که این موضوع بر مزیت HMM می‌افزاید. در فراوانی تداوم‌های تر و خشک هر دو مدل تمایل بیشتری دارند تا شبیه‌سازی تناوبی خشک و تر با تداوم یک



شکل ۲۴- فراوانی نسبی تداوم‌های تر و خشک گرگان



شکل ۲۵- فراوانی نسبی تداوم‌های تر و خشک گرگان

- Beersma JJ, Buishand TA (۲۰۰۳) Multi-site simulation of daily precipitation and temperature conditional on the atmospheric circulation. *Climate Research* ۲۵(۲):۱۲۱-۱۳۳.
- Buishand TA, Brandsma T (۲۰۰۱) Multisite simulation of daily precipitation and temperature in the Rhine basin by nearest-neighbor resampling. *Water Resources Research* ۳۷(۱۱):۲۷۶۱-۲۷۷۶.
- Ejlali N, Pezeshk H. (۲۰۰۹) A Bidirectional hidden markov model in linear memory. *Statistical Sciences*. ۲(۲):۱۳۱-۱۴۸ (In Farsi)
- Ghamghami M, Ghahreman N, Bazrafshan J (۲۰۱۵) Spatial-Temporal modeling of occurrence and amount of winter rainfall using hidden Markov model. *Watershed Management Research* ۶(۱۲):۱۳۹-۱۵۳.
- Ghamghami M, Ghahreman N, Araghinejad Sh (۲۰۱۰) Application of a non parametric approach for simulation of rainfall and temperature in terms of climate change. *Journal of Climate Research* ۱(۳,۴):۷۵-۹۴ (In Farsi).
- Ghamghami M, Ghahreman N Araghinejad Sh (۲۰۱۱) An evaluation of the performance of an advanced approach of the K-nearest neighbor in simulating the daily meteorological data. *Iranian Journal of Soil and Water Research* ۴۲(۱):۴۵-۵۴ (In Farsi).
- Hejazi Zadeh Z Fattahi E (۲۰۰۴) Synoptic patterns analysis of winter precipitation in Iran. *Iranian Journal of Geography* ۳:۸۹-۱۰۷ (In Farsi).
- Hughes JP, Guttorp P (۱۹۹۴) A class of stochastic models for relating synoptic atmospheric patterns to regional hydrologic phenomena. *Water Resources Research* ۳۰(۵):۱۵۳۵-۱۵۴۶.
- Lall U, Sharma A (۱۹۹۶) A nearest neighbor bootstrap for time series resampling. *Water Resources Research* ۳۲(۳):۶۷۹-۶۹۳.
- Maruddani B, Kurniawan A, Sugihartono, Munir A (۲۰۱۰) Rain fade modeling using hidden markov model for tropical area. In: Proc. of PIERS, ۵-۸ July, Cambridge, USA, ۹۶-۱۰۰.
- Mehrotra R, Srikanthan R, Sharma A (۲۰۰۶) A comparison of three stochastic multisite

روزه داشته باشند. در مجموع مدل HMM به عنوان یک روش پارامتری دارای برتری نسبت به KNN به عنوان یک روش ناپارامتری است که دلیل این برتری درج بیشتر محاسبات ریاضی در ساختار HMM است. با وجود این در مدل‌های پارامتری، ساختار پیچیده ریاضیاتی و فهم و درک دشوار آن، و افزایش نمایی تعداد پارامترها با افزایش تعداد ایستگاه‌ها و حالات جوی، امکان استفاده از این مدل‌ها، جهت حفظ ساختار همبستگی‌های زمانی و مکانی دشوار بوده که روش ناپارامتری می‌تواند جایگزین مناسبی در کاربری‌های ساده‌تر باشد، گرچه مدل‌های ناپارامتری نیز به تعیین مقادیر تعداد همسایه‌ها، طول پنجره متحرک و تعداد نزدیک‌ترین همسایه‌ها (K) به عنوان مقادیر پایه نیاز دارند. به دلیل تفاوت‌های اقلیمی در سطح کشور و تاثیر پذیری بارندگی از شرایط مختلف توپوگرافی و توده‌های مختلف جوی، بهتر است مطالعه در اقلیم مختلف به صورت جداگانه انجام شده و کارکرد مدل‌ها مقایسه شوند. از مولدهای استوکاستیک وضع هوا می‌توان در مطالعات تغییر اقلیم نیز استفاده کرد. گرچه مدل‌های بسیاری برای ارزیابی تاثیرات تغییر اقلیم ارائه شده است که از مهم‌ترین آنها مدل‌های گردش عمومی جو است، اما بزرگ مقیاس بودن این مدل‌ها، جهت شبیه‌سازی تغییرات اقلیم در مقیاس منطقه‌ای و محلی به خصوص در رابطه با بارندگی، قابل استفاده نمی‌باشند. مولدهای وضع هوا می‌توانند در این زمینه ابزار قدرتمندی جهت تبدیل اطلاعات بزرگ مقیاس مدل‌های گردش عمومی جو به داده‌های خرد مقیاس و ارزیابی تاثیرات هیدرولوژیکی تغییرات احتمالی آینده در گام‌های زمانی روزانه باشند.

پی‌نوشت‌ها

- ۱-Weather Generator (WG)
- ۲-Hidden Markov Model (HMM)
- ۳-K- Nearest Neighbor (KNN)
- ۴-Perturbation
- ۵-Multisite
- ۶-Power transformation
- ۷-Boostraping
- ۸-Log-odds ratio

۵- مراجع

- Ailliot P, Thompson C, Thompson P (۲۰۰۹) Space time modeling of precipitation using a hidden Markov model and censored Gaussian distributions. *Journal of the Royal Statistical Society* ۵۸(۳):۴۰۵-۴۲۶.

- Thyer M, Kuczera G (۲۰۰۳) A hidden markov model for modeling long-term persistence in multi-site rainfall time series, ۲. Real data analysis. Journal of Hydrology ۲۷۵(۱-۲):۲۷-۴۸.
- Wilks DS, Wilby RL (۱۹۹۹) The weather generator game: A review of stochastic weather models. Progress in Physical Geography ۲۳(۳):۳۲۹-۳۵۷.
- Yates D, Gangopadhyay S, Rajagopalan B, Strzepek K (۲۰۰۳) A technique for generating regional climate scenarios using a nearest neighbor algorithm. Water Resources Research ۳۹(۷):SWG۷-۱-۷-۱۵.
- Young KC (۱۹۹۴) A multivariate chain model for simulating climate parameters with daily data. Journal of Applied Meteorology ۳۳(۶):۶۶۱-۶۷۱.
- Zucchini W, Guttorp P (۱۹۹۱) A hidden markov model for space-time precipitation. Water Resources Research ۲۷(۸):۱۹۱۷-۱۹۲۳.
- precipitation occurrence generators. Journal of Hydrology ۳۳۱(۱-۲):۲۸۰-۲۹۲.
- Rajagopalan B, Lall U (۱۹۹۹) A K-nearest-neighbor simulator for daily precipitation and other weather variables. Water Resources Research ۳۵(۱۰):۳۰۸۹-۳۱۰۱.
- Robertson AW, Kirshner S, Smyth P (۲۰۰۴) Downscaling of daily rainfall occurrence over Northeast Brazil using a hidden markov model. Journal of climate ۱۷(۲۲):۴۴۰۷-۴۴۲۴.
- Sharif M, Burn DH (۲۰۰۷) An improved K-nearest neighbor weather generating model. Hydrologic Engineering ۱۲(۱):۴۲-۵۱.
- Sharif M, Burn DH (۲۰۰۶) Simulating climate change scenarios using an improved k-nearest neighbor model. Journal of Hydrology ۳۲۵:۱۷۹-۱۹۶.