طراحي يك مدل MultiFilter تطبيقي از نوع MISO
جهت شبيه سازي و پيش بيني ديناميك و بهنگام جريان رودخانه‌ها

ناصر رستم افشار، هدايت فهمي، عليرضا پيره

۱- استاديار دانشگاه صنعت آب و برق
۲- وزارت نيرو
۳- كارشناس مهندسين مشاو جاماب arpireh@yahoo.com

چكيده
مقاله حاضر معماري خاصي از نحوه قرار گيري فيلترهاي حالت كالمن را در ساختار يك MultiFilter (MF)[1]، مورد تحليل و طراحي قرار داده است. الگوي حاضر در ساختمان اين مدل اقتباسي از ساختار و توپولوژي شبكه‌هاي عصبي چند لايه مي‌باشد. نتايج حاصل از كاربرد اين مدل با عملكرد يك شبكه عصبي MLP چند لايه مورد مقايسه و ارزيابي قرار گرفته است. مطالعه موردي روي رودخانه باراندوزچاي در غرب درياچه اروميه انجام گرفته است.

واژه‌هاي كليدي: فيلتر كالمن، شبكه عصبي، MultiFilter ، جريان رودخانه

۱- مقدمه
عدم قطعيت از طبيعت فازي فرآيندهاي جوي مانند تبخير، بارندگي و درجه حرارت ناشي مي‌شود. در اين تحقيق توسط تحليل فوريه معادلات كالمن و طراحي يك MultiFilter با فيلترهايي، در حالت MIMO[2]، MISO[3] و SISO[4] شبيه سازي تطبيقي جريان رودخانه باراندوزچاي در غرب درياچة اروميه مورد بررسي قرار گرفته است. نتايج حاصله از اين تحقيق نشان دهندة كاهش قابل توجه واريانس خطاي شبيه سازي تطبيقي جريان رودخانه‌ها از طريق اعمال يك فيلتر تركيبي نسبت به كاربرد الگوريتم فيلتر كالمن مي‌باشد. معماري مدل حاضر از الگوي نحوه قرارگيري نرون‌ها درون يك شبكه عصبي برداشته شده است و تا زماني كه مدل از نظر ورودي‌هاي جديد تغذيه شود، قادر خواهد

[1] چند فيلتري

[2] Multy-Input Multy-Output (MIMO)
[3] Multy-Input Single -Output (MISO)
[4] Single-Input Single-Output (SISO)

بود همزمان با آموزش، پیش بيني را به صورت بهنگام انجام دهد. قابليت‌ها و خروجي نهايي مدل حاضر با عملكرد يك شبكه عصبيMLP مورد مقايسه و تحليل قرار گرفته است.

۲- تجزيه و تحليل معادله فوريه

اگر متغير هيدرولوژيكي در زمان i برابر $x(i)$ باشد, آنگاه ساختار رياضي آن به صورت معادله (۱) ارائه مي‌شود:

$$x(i) = M_x + \sum_{k=1}^{m} [A_k SIN(\gamma ki) + B_k COS(\gamma ki)] + \omega(i) \qquad (۱)$$

M_x متوسط كل جريان تا زمان, $\gamma = \frac{2\pi}{T}$ فركانس معادله فوريه, T دوره تناوب تابع براي سيستم‌هاي فصلي, A_k, B_K ضرايب‌هارمونيك مدل و بالاخره $\omega(i)$ قسمت استوكـاستيك مدل می باشد (Heemen et al. 1998, Rafael and Baras, 1984).

۳- سيستم مدل

در اين مدل, معادله فوريه به عنوان بردار متغير حالت در نظر گرفته شده است. قانون انتقال بردار حالت, به صورت ماتريس معادله (۲) ارائه مي‌شود (Bergman and Delleur, 1985).

$$\begin{bmatrix} x(i) \\ M(i) \\ A_1(i) \\ B_1(i) \\ A_2(i) \\ B_2(i) \\ \vdots \\ A_m(i) \\ B_m(i) \end{bmatrix} = \begin{bmatrix} 1 & 0 & \alpha_1 & \beta_1 & \alpha_2 & \beta_2 & \dots & \alpha_m & \beta_m \\ 0 & 1 & 0 & 0 & 0 & 0 & & 0 & 0 \\ 0 & 0 & 1 & 0 & 0 & 0 & & 0 & 0 \\ 0 & 0 & 0 & 1 & 0 & 0 & & 0 & 0 \\ 0 & 0 & 0 & 0 & 1 & 0 & & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & 1 & & 0 & 0 \\ \vdots & \vdots & \vdots & \vdots & \vdots & \vdots & \vdots & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & 0 & & 1 & 0 \\ 0 & 0 & 0 & 0 & 0 & 0 & \cdots & 0 & 1 \end{bmatrix} \cdot \begin{bmatrix} x(i-1) \\ M(i-1) \\ A_1(i-1) \\ B_1(i-1) \\ A_2(i-1) \\ B_2(i-1) \\ \vdots \\ A_m(i-1) \\ B_m(i-1) \end{bmatrix} + \begin{bmatrix} \omega(i) \\ 0 \\ 0 \\ 0 \\ 0 \\ 0 \\ \vdots \\ 0 \\ 0 \end{bmatrix} \qquad (۲)$$

نمايش ديگري از معادله (۲) به صورت معادله خطي (۳) مي‌باشد:

$$Y(i) = \phi(i, i-1)Y(i-1) + W(i) \qquad (۳)$$

W(i) نشان دهنده بردار خطا با توزيع $W(i) \approx (0, Q)$ مي‌باشد.

٤- مدل مشاهده‌اي[5]

اگر بردار اندازه گيري در زمان (i) را با $Z(i)$ و مقدار شبيه سازي شده آن (بردار حالت سيستم) با $Y(i)$ نشان داده شود، آنگاه رابطه تبادلي بين اين دو بردار به صورت معادله (٤) خواهد بود (Bergman and Delleur, 1985, Brown 2000, Gustafon, 2000, Rafael and Baras, 1984):

$$Z(i) = H(i).Y(i) + V(i) \qquad (٤)$$

$V(i)$ نويز سفيد[6] با توزيع $V(i) \approx (0, R)$ مي‌باشد. ماتريس $H(i)$ به شكل معادله (٥) خواهد بود:

$$H(i) = \begin{bmatrix} 1 & 0 & 0 & \cdots & 0 \end{bmatrix} \qquad (٥)$$

٥- معادلات فيلتر كالمن[7]:

اگر بردار حالت اوليه پيش‌بيني شده براي الگوريتم كالمن $\hat{Y}(i-1|i-1)$ و ماتريس كوواريانس خطاي اوليـه, $P(i-1|i-1)$ با عناصر P_{ij} كه $i, j = 1,2,3,.....(2m+2)$ مشخص باشند, آنگاه معادلات انتقال در فضاي حالت كالمن به صورت معادلات (٦) و (٧) خواهند بود:

$$\hat{Y}(i|i-1) = \phi(i, i-1)\hat{Y}(i-1|i-1) \qquad (٦)$$

$$P(i|i-1) = \phi(i, i-1)P(i-1|i-1)\phi(i, i-1) + Q(i) \qquad (٧)$$

فيلتر كالمن با معادله (٨) بيان مي‌شود (Bergman and Delleur, 1985, Brown 2000, Gustafon, 2000, Rafael and Baras, 1984):

$$K(i) = P(i|i-1)H^T(i)[H(i).P(i|i-1)H^T(i) + R(i)]^{-1} \qquad (٨)$$

عمل بهنگام كردن بردار حالت با بردار اندازه گيري در زمان (i) توسط معادلات (٩) و (١٠) صورت مي‌گيرد.

---

[5] Observation model
[6] White Noise
[7] Kalman Filter Equations

$$\hat{Y}(i|i) = \hat{Y}(i|i-1) + K(i)[Z(i) - H(i)\hat{Y}(i|i-1)] \quad (٩)$$

$$P(i|i) = [I - K(i)H(i)]P(i|i-1) \quad (١٠)$$

که در آن I ماتريس واحد مي‌باشد. معادلات (٦) تا (١٠) به معادلات فيلتر كالمن مشهور هستند.

٦- معادلات فيلتر كالمن براي فرآيندهاي پريوديك (سري هاي ديناميكي):

معادله فيلتر كالمن را مي‌توان از طريق جاي‌گذاري معادله (٥) و (٧) در معادله (٨) و انجام مقداري عمليات جبري طبق معادله (١١) به دست آورد: (Bergman and Delleur, 1985, Brown 2000, Gustafon, 2000, Rafael and Baras, 1984):

$$K^T(i) = [\beta_{11}/\sigma \quad \eta_{12}/\sigma \quad \eta_{13}/\sigma \quad \cdots \quad \eta_{1k}/\sigma]^T \quad (١١)$$

كه در آن: $\sigma = \beta_{11} + R(i)$ و

$$\beta_{11} = \eta_{11} + \sum_{j=1}^{m}(\alpha_j.\eta_{1,2j+1} + \beta_j.\eta_{1,2j+1}), \quad \eta_{1i} = P_{1i} + \sum_{j=1}^{m}(\alpha_j.P_{i,2j+1} + \beta_j.P_{i,2j+2})$$

ماتريس بهنگام شده كـوواريانس خـطا با قرار دادن معـادلات (٥) و(٧) و (١١) در معادلـــه (١٠) به دست مي‌آيد.

$$P(i|i) = \begin{bmatrix} (\beta_{11} - \beta_{11}{}^2/\sigma) & (\eta_{12} - \beta_{11}\eta_{12}/\sigma) & \cdots & (\eta_{1k} - \beta_{11}\eta_{1k}/\sigma) \\ (\eta_{12} - \beta_{11}\eta_{12}/\sigma) & (P_{22} - \eta^2{}_{12})/\sigma) & & (P_{2k} - \eta_{1k}\eta_{12}/\sigma) \\ (\eta_{13} - \beta_{11}\eta_{13}/\sigma) & (P_{23} - \eta_{13}\eta_{12}/\sigma) & & (P_{3k} - \eta_{1k}\eta_{13}/\sigma) \\ & & \vdots & \vdots \\ (\eta_{1k} - \beta_{11}\eta_{1k}/\sigma) & (P_{2k} - \eta_{1k}\eta_{12}/\sigma) & \cdots & (P_{kk} - \eta^2{}_{1k})/\sigma) \end{bmatrix} \quad (١٢)$$

اعضاي ماتريس (١٢) در زمان $i-1$ مشخص مي‌باشند. در يك فيلتر بهينه كالمن همواره $traceP(i|i) \le traceP(i-1|i-1)$ خواهد بود. با جاي‌گذاري معادلات (٥) و (٦) و (١١) در معادله (٩) بردار حالت بهنگام شده بدست مي‌آيد:

$$\hat{Y}(i|i)=\begin{bmatrix}\hat{x}(i|i)\\ \hat{M}(i|i)\\ \hat{A}_1(i|i)\\ \hat{B}_1(i|i)\\ \hat{A}_2(i|i)\\ \hat{B}_2(i|i)\\ \vdots\\ \hat{A}_m(i|i)\\ \hat{B}_m(i|i)\end{bmatrix}=\begin{bmatrix}\hat{x}(i|i-1)\\ \hat{M}(i|i-1)\\ \hat{A}_1(i|i-1)\\ \hat{B}_1(i|i-1)\\ \hat{A}_2(i|i-1)\\ \hat{B}_2(i|i-1)\\ \vdots\\ \hat{A}_m(i|i-1)\\ \hat{B}_m(i|i-1)\end{bmatrix}+\begin{bmatrix}\beta_{11}/\sigma\\ \eta_{12}/\sigma\\ \eta_{13}/\sigma\\ \eta_{14}/\sigma\\ \eta_{15}/\sigma\\ \eta_{16}/\sigma\\ \\ \eta_{1k-1}/\sigma\\ \eta_{1k}/\sigma\end{bmatrix}[Z(i)-\hat{x}(i|i-1)] \qquad (۱۳)$$

بعد از اینکه پیش‌بیني بردار حالت سیستم در زمان i توسط معادله (۱۳) بهنگام شد, براي بردار اندازه گیري جدید و بهنگام کردن بردار حالت توسط آن، به معادله (٦) برگشته و همان روند تا معادله (۱۳) تکرار خواهد شد.

۷- ساختار مدل MF

جریان رودخانه در زمان(i) بصورت تابعی از بارش و دماي حوزه و جریان رودخانه بهنگام شده در نظرگرفته مي‌شود. $T^U(i+n), Q^U(i+n), R^U(i+n)$ به ترتیب بارش، دبي و دماي بهنگام شده مي‌باشند.

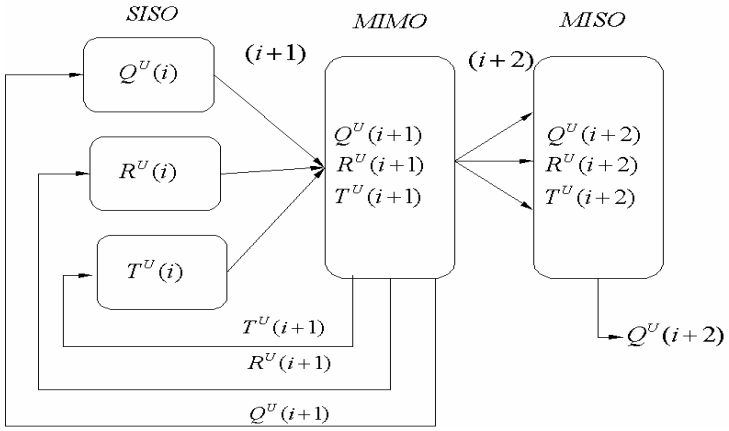

شکل ۱- طرح قرارگیري فیلترها در مرحله پیش بیني مدل MF

در مرحله شبیه سازی سه فیلتر کالمن در حالت SISO و یک فیلتر در حالت MIMO و یک فیلتر در حالت MISO شبیه سازی را روی بازه زمانی (بردارهای اندازه گیری در مرحله شبیه سازی)، [0,1] شروع مي‌کنند. فیلترهای SISO که هرکدام به طور مستقل شبیه ساز دما، دبي و بارش مي‌باشند،

کار خود را از نقطه زماني صفر، فيلترMIMO با سه ورودي و خروجي همزمان دبي، بارش و دما کار خود را از نقطه زمانی يك و فيلترMISO با سه ورودي بارش، دما و دبي و تك خروجي دبي از نقطه زمانی دو، همزمان در طول بازه مورد نظر جهت به دست آوردن بهينه ترين تطبيق مدل، تا فيلتر کردن آخرين بردار اندازه گيری ادامه مي‌دهند. ديورژانس ماتريس کوواريانس خطا در فيلتر کالمن وقتی زمان شبيه سازی به سمت بينهايت ميل کند به سمت صفر ميل خواهد کرد، از اين رو سيستم اين مدل چه در جز و چه در کل روندی قطعی جهت کاهش خطا در طول مدت شبيه سازی و پيش بينی در پيش خواهد گرفت. در مرحله پيش بينی سه فيلتر کالمن در حالت SISO و فيلتر MIMO داخل يک چرخه قرار گرفته و همراه با فيلتر SISO آرايشی حلقوي به شکل (١) پيدا مي‌کنند. خروجی نهايی مدل در مرحله پيش بيني ميزان جريان در ماه های i+12,...,i+2, i+1 خواهد بود. بدين ترتيب جريان ماهانه يک سال را مي‌توان با دقتی مناسب و قابل قبول پيش بينی کرد.

٨- مباني ساختار شبکه‌هاي عصبي مصنوعي MLP

هر نرون (واحد محاسباتي) در شبکه‌هاي عصبي مصنوعي چند لايه پيشخور که عموماً شبکه‌هاي عصبي چند لايه پرسپترون Multy Layer Perceptron (MLP) ناميده مي‌شوند، دو محاسبه انجام مي‌دهد، در محاسبه اول سيگنال تابعي و در محاسبه دوم تخمين لحظه‌اي گراديان منحني خطا را نسبت به پارامترهايي که ورودي نرون را به خود نرون وصل مي‌کند، در اختيار قرار مي‌دهد. اين گراديان‌ها جهت پخش سيگنال خطا در شبکه مورد نياز مي‌باشند (Kue et al. 1993). در شکل (١) نمايش قراردادي يك شبکه MLP با توپولوژي (١-٢-٤-٢) ارائه شده است.

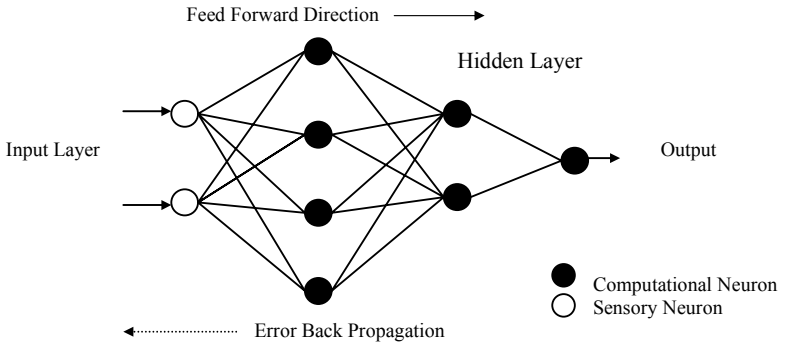

شکل ٢- نمايش قراردادي ساختار شبکه MLP با توپولوژي (١-٢-٤-٢)

ارتباطات درون ساختمان شبکه توسط ماتریس وزن‌ها (w_i) برقرار مي‌شود. ورودي خالص هر نرون تابعي از ماتريس وزن‌ها و اطلاعات رسيده به آن نرون (x_i) مي‌باشد و از رابطه (١٤) بدست مي‌آيد.

$$net = \sum_{i=1}^{n} w_i x_i + \theta \qquad (١٤)$$

θ= وزن بایاس. خروجي هر نرون با استفاده از تابع (Sigmoid) توسط رابطه (١٥) به دست مي‌آيد.

$$F(net) = \frac{1}{1+\exp(-net)} \qquad (١٥)$$

در هر الگوريتم آموزشي هدف حداقل كردن خطاي شبكه است كه بصورت رابطه (١٦) تعريف مي‌شود.

$$E = \frac{1}{PN_{output}} \sum_{P}^{P} \sum_{i=1}^{N_{output}} (t_i - o_i)^2 \qquad (١٦)$$

P= تعداد الگوهاي آموزشي، N= تعداد نرون‌هاي خروجي، o_i= مقدار مشاهده شده، t_i= مقدار محاسبه شده توسط شبكه مى باشند. براي آموزش كليه شبكه‌هاي طراحي شده از روش (Levenberg-Marquardt) استفاده گرديد (Howard and Mark, 2001).

٩- كاربرد عملي مدل

جريان ماهانه رودخانه باراندوزچاي در غرب درياچه اروميه در ايستگاه بابارود (ايستگاه خروجي حوزه) به مدت ١٠ سال مابين سال‌هاي (١٣٧٧-١٣٦٧) جهت آموزش و به مدت دو سال مابين سال‌هاي (٧٩-٧٧)، جهت صحت يابي شبكه‌ها و سال آبي٨٠-١٣٧٩ جهت پيش بيني مد نظر

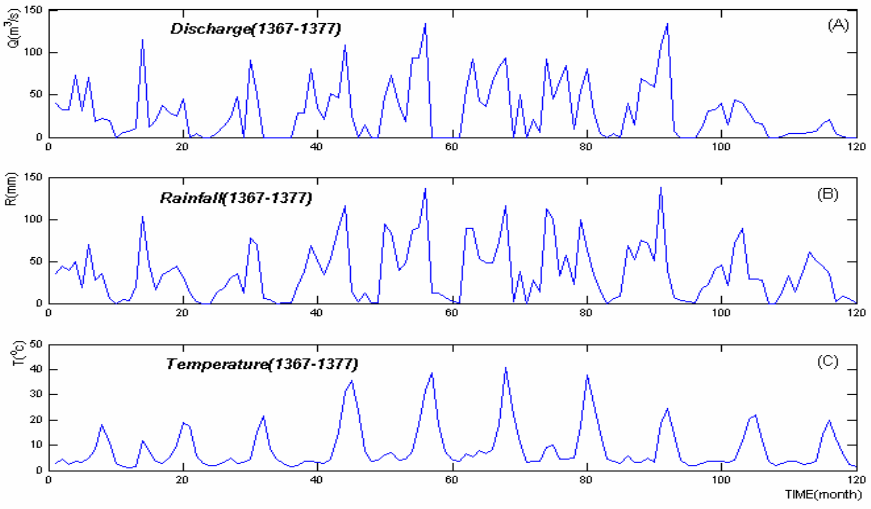

شكل٣- نمودار مقادير مشاهده شده، A: جريان رودخانه B: بارندگي C: دما

قرارگرفت. نمودار مقادير اندازه گيري شده جريان ماهانه رودخانه، دما و بارش متوسط ماهانه در سال‌هاي مورد نظر جهت آموزش شبکه در شکل (۳) آورده شده است.

در اين تحقيق، جريان رودخانه در زمان (i) ام در شبيه سازي توسط شبکه عصبي به صورت توابع (۱۷) تا (۲۲) مد نظر قرار گرفت.

$$Q(i) = F\left(Q(i-2), Q(i-1), R(i-1), T(i-1), T(i), R(i)\right) \quad (۱۷)$$

$$Q(i) = F\left(Q(i-2), Q(i-1), R(i-2), R(i-1), T(i-2), T(i-1), T(i), R(i)\right) \quad (۱۸)$$

$$Q(i) = F\left(Q(i-1), R(i-1), T(i-1), T(i), R(i)\right) \quad (۱۹)$$

$$Q(i) = F\left(Q(i-1), R(i-1), R(i)\right) \quad (۲۰)$$

$$Q(i) = F\left(R(i-2), R(i-1), T(i-2), T(i-1), T(i), R(i)\right) \quad (۲۱)$$

$$Q(i) = F\left(Q(i-3), Q(i-2), Q(i-1), R(i)\right) \quad (۲۲)$$

$Q(i-n)$ ، $R(i-n)$ ، $T(i-n)$= به ترتيب دبي، بارش و دماي متوسط در n پله زماني ماقبل زمان (i) ام می باشند. در مرحله پيش بيني جريان در شبکه عصبي براي سال (۸۰-۷۹)، ورودي بارش در زمان(i) ام، سال آبي مذکور از طريق مدل(FSAM)[8] برآورد خواهد شد. دماي ماهانه بهنگام براي دوازده ماه اين سال نيز توسط دوازده شبکه عصبي طراحي شده، پيش بيني مي‌گردد. تمامي عمليات‌ها در محيط نرم افزار MATLAB انجام شده است.

[8] Fourier Series ARIMA Model (FSAM)

۱۰- شبيه سازي‌ها در مدل MF وشبكه عصبي MLP

نمودارهاي عملكرد فيلترهاي SISO، MISO، MIMO و MF در مرحله شبيه سازي در شكل‌هاي شماره (٤) آورده شده است.

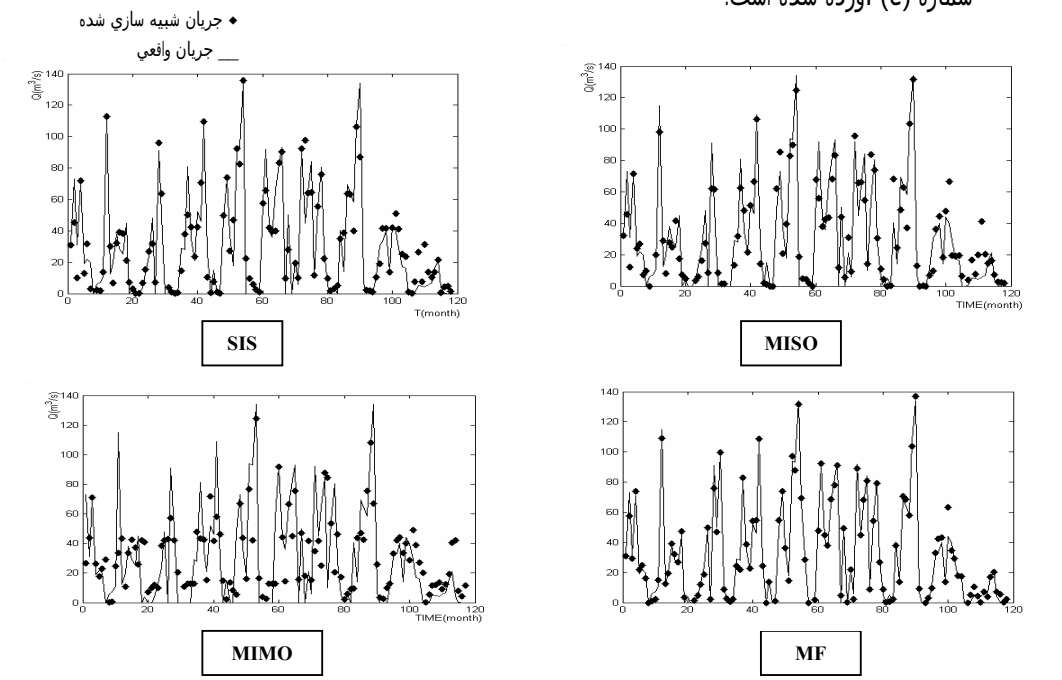

شكل ٤- نمودارهاي مقادير واقعي و شبيه سازي شده توسط فيلترهاي SISO، MISO، MIMO و مدل MF

شبيه سازي توابع (۱) تا (٦) به وسيله طراحي شش شبكه عصبي انجام گرديد. نمودار مقادير واقعي و شبيه سازي شده در شكل شماره (۵) آورده شده است.

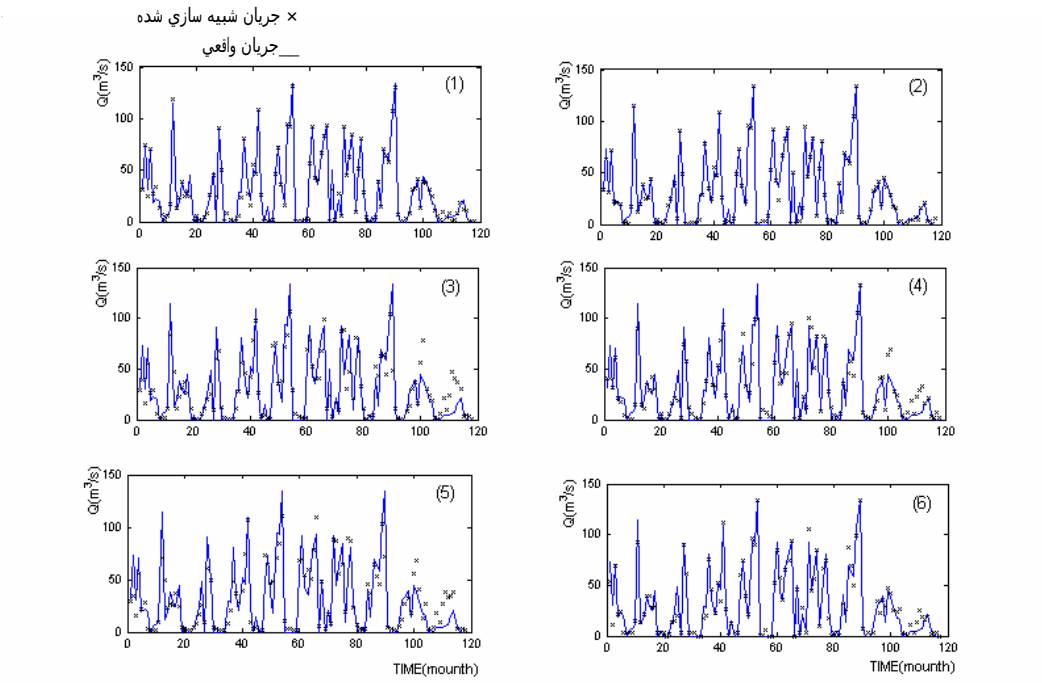

شكل ۵- نمودارهاي مقادير واقعي و شبيه سازي شده توابع (۱) تا (٦) توسط شبكه عصبي MLP

نمودارهاي مقادير پيش بيني شده و مقادير واقعي براي مدل‌هاي MF و شبكه‌هاي عصبي MLP در شكل‌هاي (٦) و (۷) آمده است.

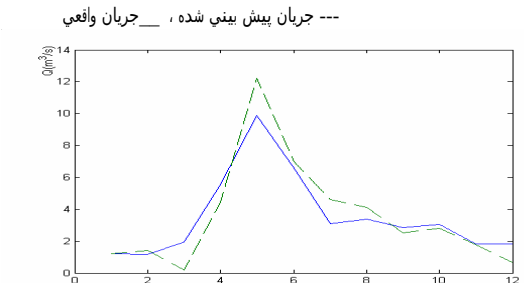

شكل ٦- نمودار مقادير واقعي و پيش بيني شده توسط مدل MF

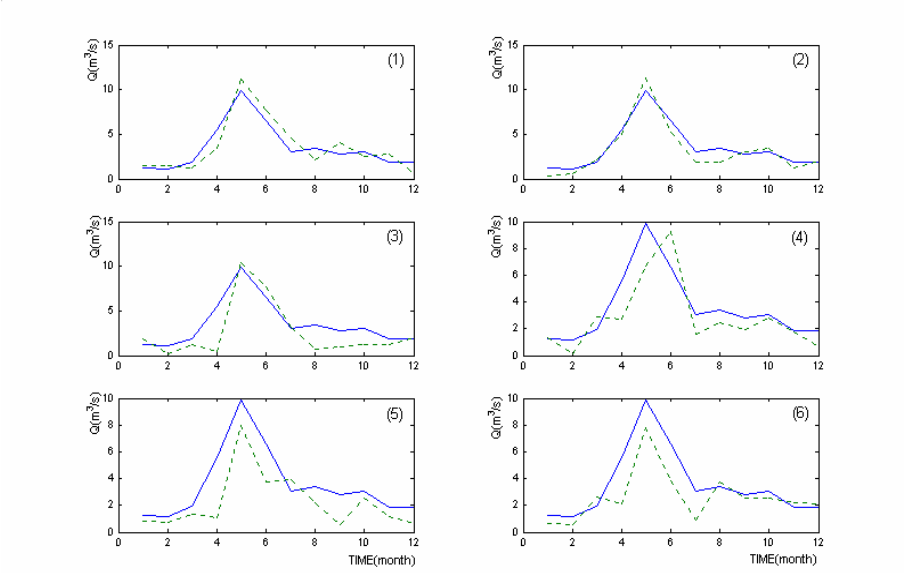

شكل ۷- نمودارهاي مقادير واقعي و پيش بيني شده توابع (۱) تا (٦) توسط شبكه عصبي MLP

۱۱- بررسي خطاي شبيه سازي در مدل MF و شبكه عصبيMLP

شكل (۹) تغييرات واريانس خطا را روي پله‌هاي زماني متوالي را در مدل MF نشان مي‌دهد. واريانس خطاي شبيه سازي اولين پله زماني از ۰/۱۸ به ۰/۰۲ در آخرين پله تقليل يافته است.R^2، ضريب نيكويي برازش سات‌كليف(Sutcliffe)، RMSE و MSE در آخرين پله شبيه سازي به ترتيب برابر ۰/۹۸۳٦٥، ۰/۵۳۲٦ و ۰/۰۰۲٦۹ به دست آمد. در شبكه عصبي MLP با توپولوژي (۱-۳-۵)، بر روي تابع شماره (۲) با بهترين شبيه سازي و پيش بيني، مقدار هدف براساس مقدارMSE، شكل (۸)، برابر ۰/۰۰۳۵ (مرز over training مدل) تعريف شده است.R^2، ضريب نيكويي برازش سات‌كليف، RMSE در آخرين چرخه آموزشي به ترتيب برابر ۰/۹۹٤٥٦، ۰/۰٦۱٥٤ به دست آمد.

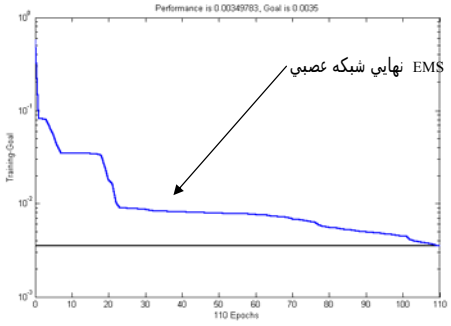

شكل ۸- تغييراتMSE در آموزش شبكه عصبي MLP

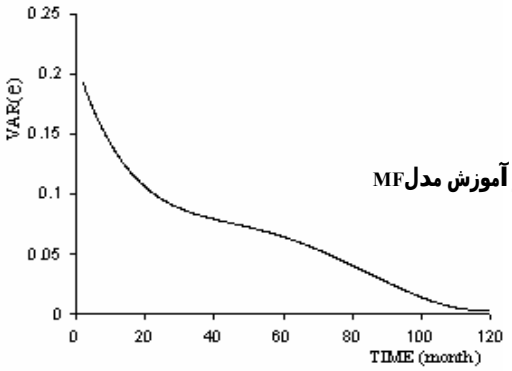

شكل ۹- تغييرات واريانس خطا در آموزش مدلMF

۱۲- جمع بندي كلي و نتايج

معادلات فيلتر كالمن يك الگوريتم رياضي بهينه را جهت پيش بيني وضعيت آينده سيستم، براساس وضعيت فعلي و گذشته آن ارائه مي‌دهند. اين فيلتر در صورتي كه بردارهاي اندازه گيري به سمت بينهايت ميل كنند قادر است واريانس خطاي شبيه سازي جريان را به سمت صفر ميل دهد. طبيعتاً شبيه سازي دقيق از يك سيستم ديناميك, خطاي پيش بيني رفتار آينده آن را كاهش خواهد داد, بنابراين افزايش دقت شبيه‌سازي در بازه‌هاي زماني محدود, به نسبت وسعت بازه, پيش‌بيني آينده سيستم را با دقتي مناسب امكان پذير خواهد نمود. از نقطه نظر دقت در شبيه سازي، مدل MF نسبت به شبكه عصبي كار خود را با خطاي بالاتري شروع كرده ولي با سرعت بسيار زيادي به EMS پايين‌تر از شبكه عصبي رسيد. پس از آموزش شبكه عصبي، مدل مذكور براساس آموزش، در بازه زماني محدود داده‌هاي آموزشي، پيش بيني دبي سال۸۰-۱۳۷۹ را با خطايي در حدود۱۰ درصد روي تـــابع شماره (۲) انجام داد. اين پيش بيني در حالي انجام شده است كه شبكه از خروجي‌هاي يك مدل پيش بيني كننده بارش (FSAM)، همچنين پيش بيني‌هاي دوازده شبكه عصبي طراحي شده براي پيش بيني دماي دوازده ماه سال استفاده كرده است. درصورتيكه در مدل MF كليه مراحل شبيه سازي، و توليد داده جهت انجام پيش بيني توسط خود مدل پذيرفته است. ورودي‌هاي مدل MF نيز كمتر از نصف ورودي‌هاي شبكه عصبي در بهترين حالت شبيه سازي بوده است. خطاي پيش بيني در مدلMF برابر۱۱ درصد به دست آمده كه تفاوت اين خطا در قياس با شبكه عصبي قابل چشم پوشي مي‌باشد، اين بدان علت است كه آموزش شبكه عصبي تمام شده و پيش بيني آن استاتيك خواهد بود، در حالي كه مدل MF به محض دريافت ورودي براي هر ماه قادر است پيش بيني ماه‌هاي بعدي خود را بهنگام كند و نمايشي از يك شبيه سازي و پيش بيني ديناميك را ارائه دهد. قدرت شبيه سازي يك فيلتر در قياس با يك نرون بينهايت بيشتر بوده، به طوري كه يك فيلتر در حالت SISO قادر است به تنهايي نوسانات يك سيستم ديناميك را شبيه سازي كند. در حالي كه ساختمان رياضي يك نرون معادله رگرسيون خطي ساده با قدرت بسيار محدود مي‌باشد.

تجمع چند فيلتر در ساختار مدل MF در سه لايه، عملكردي به مراتب قوي‌تر با سرعت كاهش خطاي بالا نسبت به عملكرد چندين شبكه عصبي طراحي شده در توپولوژي‌هاي مختلف نشان داد. بنابراين جهت رعايت اصل امساك در مدل سازي و همچنين كاهش هرچه بيشتر ورودي‌هاي مورد نياز جهت شبيه سازي‌ها با حفظ دقت در شبيه سازي و پيش بيني، مدل MF مي‌تواند بسيار كارآمد باشد.

منابع

Bergman, M.J., J.W. Delleur, "Kalman Filtering Estimation and Prediction of Daily Stream Flow: (I). Review, Algorithm, and Simulation Experiments". American Water Resources Association (AWRA), VOL.21, NO.5, PP.143-155, 1985.

Brown, R.G., "Introduction to Random Signal and Kalman Filtering", John Wily, 347P, 2000.

Gustafson, F., "Adaptive Filtering and Change Detection", John Wily, 500P, 2000.

Heemin, A.W., H.J. Vested, R. Canizares, "Application of Advanced Data Assimilation Methods for the Initialization of Storm Surge Models", Journal of Hydraulic Research, Vol. 3, PP.655-674, 1998.

Howard. D, B. Mark, User's Guide for Neural Network Toolbox with MATLAB. Version6.1.0.450., 2001.

Kuo, L. H., V. G. Hoshin, and S. Sorooshian, Artificial Neural Network Modeling of the Rainfall-runoff process, Published in Water Resources, The University of Arizona, 29(4): 85- 1194, 1993.

Rafael, L., I. R. Baras, "Random Functions in Hydrology", John Wily, 455P, 1984.

Wood, E.F., P. E. Connel, "Real Time Forecasting in Hydrological Forecasting", John Wily, 485P, 1984.