



تعیین ضرایب شبکه‌های عصبی نوع GMDH با استفاده از فیلتر کالمن UKF

مجتبی معصوم نژاد^{1*}، علی جمالی²، نادر نریمانزاده³

1- مربی، مهندسی مکانیک، دانشگاه فنی و حرفه‌ای، رشت

2- استادیار مهندسی مکانیک، دانشگاه گیلان، رشت

3- استاد، مهندسی مکانیک، دانشگاه گیلان، رشت

* رشت، صندوق پستی 3756، masoumnezhad@tvu.ac.ir

چکیده

اطلاعات مقاله

مقاله پژوهشی کامل

دریافت: 31 خرداد 1393

پذیرش: 03 مرداد 1393

ارائه در سایت: 28 مهر 1393

کلید واژگان:

شبکه‌های عصبی نوع GMDH

فیلتر کالمن آنسنتد (UKF)

نامعینی

شناسایی پارامترها

شناسایی مدل

فیلتر کالمن آنسنتد (UKF) یکی از معروف‌ترین فیلترها جهت تخمین متغیرهای حالت آغشته با نویز گوسی و سفید یک سیستم غیرخطی است. همچنین، این فیلتر در تخمین پارامترهای شبکه‌های عصبی چند لایه‌ای نیز مورد استفاده قرار می‌گیرد. شبکه عصبی نوع GMDH یکی از پرکاربردترین شبکه‌های عصبی است که از توانایی بالایی در مدل‌سازی داده‌های پیچیده برخوردار است. در تحقیق‌های زیادی از روش‌های گوناگون نظیر تجزیه مقادیر منفرد و الگوریتم ژنتیک برای تعیین ضرایب این شبکه عصبی استفاده شده است. در این مقاله، از فیلتر کالمن آنسنتد جهت تخمین پارامترهای شبکه‌های عصبی نوع GMDH برای داده‌های آزمایشگاهی دارای قطعیت و عدم قطعیت استفاده شده است. با استفاده از این روش، ضرایب بر روی جدول داده‌های آزمایشگاهی بدون در نظر گرفتن نامعینی به‌دست آمدند و برای بررسی مقاوم بودن مدل به دست آمده در برابر نامعینی‌های موجود در داده‌ها از روش مونت کارلو استفاده شد. نتایج شبیه‌سازی برای دو جدول داده‌های آزمایشگاهی چند ورودی-یک خروجی نشان می‌دهند که الگوریتم ارائه شده نسبت به سایر روش‌ها، رفتار بسیار مقاوم‌تری در مواجهه با نامعینی‌ها دارد.

Parameter estimation of the GMDH-type neural network using UKF filter

Mojtaba Masoumnezhad^{1*}, Ali Jamali², Nader Narimanzadeh²

1- Department of Mechanical Engineering, Technical and Vocational University, Rasht, Iran.

2- Department of Mechanical Engineering, University of Guilan, Rasht, Iran.

* P.O.B. 3756 Rasht, Iran, masoumnezhad@tvu.ac.ir

ARTICLE INFORMATION

Original Research Paper
Received 21 June 2014
Accepted 25 July 2014
Available Online 20 October 2014

Keywords:
GMDH-Type Neural Network
Unscented Kalman Filter
Uncertainty
Parameter Estimation
Model Identification

ABSTRACT

The Unscented Kalman filter (UKF) is the popular approach to estimate the recursive parameter of nonlinear dynamical system corrupted with Gaussian and white noises. Also, it has been applied to train the weights of the multi-layered neural network (MNN) models. The Group method of data handling (GMDH)-type neural network is one of the most widely used neural networks having high capacity in modeling of the complex data. In many researches, different approaches are used in training of neural networks in terms of associated weights or coefficients, such as singular value decomposition and genetic algorithms. In this paper, the Unscented Kalman filter is used to train the parameters of GMDH-type neural network when the experimental data are deterministic. The effectiveness of GMDH-type neural network with UKF algorithm is demonstrated by modeling using a table of the multi input-single output experimental data. The simulation result shows that the UKF-based GMDH algorithm performs well in modeling of nonlinear systems in comparison with the results of using traditional GMDH-type neural network and is more robust against the model and measurement uncertainty.

1- مقدمه

پیچیدگی ذاتی موجود در طراحی شبکه‌های عصبی به شناسایی ساختار و ضرایب آموزش‌دهنده آن مرتبط است. الگوریتم پس انتشار یکی از متداول-ترین الگوریتم‌های مورد استفاده جهت آموزش این شبکه‌ها است، اما الگوریتم پس انتشار به انتخاب وزن‌های اولیه و تعداد نرون‌های مخفی وابسته است. همچنین، سرعت همگرایی آن خیلی کند است و به نویزهای موجود در مجموعه داده‌های ورودی و خروجی که جهت آموزش شبکه عصبی به کار می‌روند بسیار حساس است. همچنین، در مدل‌سازی فرآیندهای پیچیده عملکرد ضعیفی دارد [4,3].

جهت رفع نواقص مذکور تحقیقات گسترده‌ای انجام پذیرفته است [7-5].

شبکه‌های عصبی مصنوعی ابزارهای قدرتمندی هستند که از دانش کنونی بشر راجع به شبکه‌های عصبی موجودات زنده الهام گرفته شده‌اند و جهت شناسایی رفتار سیستم‌های خیلی پیچیده و یا نامشخص براساس داده‌های ورودی و خروجی معلوم مورد استفاده قرار می‌گیرند [1]. در این نوع شبکه‌ها هدف آن است که با استفاده از تعداد زیادی عناصر محاسباتی ساده، که با حجم زیادی از اتصالات به یکدیگر متصل شده‌اند، تابع مورد نظر به‌دست آید [2].

شبکه‌های عصبی تقریباً می‌توانند هر تابع غیرخطی را تقریب بزنند.

داده می‌شود که مدل شبکه عصبی با استفاده از فیلتر کالمن آنسند در مقابل داده‌های آزمایشگاهی مخدوش با نویز دارای عملکرد مقاوم‌تری است.

2- مدل سازی با استفاده از شبکه عصبی نوع GMDH

روش دسته‌بندی گروهی داده‌های عددی یک فن‌آوری آموزش آماری شبکه-ای است که حاصل تحقیقات سایبرنتیکی⁷ شامل سیستم‌های خود سامانده، تئوری اطلاعات، کنترل و علم کامپیوتر است.

شبکه عصبی نوع GMDH شبکه‌ای خودسازمانده و یک سویه است که این امکان را فراهم می‌آورد که مدل یک سیستم غیرخطی پیچیده با یک شبکه عصبی چندلایه‌ای تعیین شود. این شبکه از چندین لایه و هر لایه از چندین نرون تشکیل یافته است.

هدف شبکه عصبی نوع GMDH این است که با استفاده از M مجموعه داده آزمایشگاهی چند ورودی و تک خروجی معلوم، تابع $\hat{f}$ به‌گونه‌ای مشخص شود که به‌ازای بردار ورودی $X = [x_1, x_2, x_3, \dots, x_n]$ خروجی تخمین زده شده $\hat{y}$ تا حد امکان به مقدار واقعی y نزدیک باشد، تا بدین طریق مقدار تابع خطای بین خروجی واقعی و خروجی تخمین زده شده (نشان داده شده در معادله (1)) حداقل شود [21].

$$\sum_{k=1}^M [\hat{f}(x_{k1}, x_{k2}, x_{k3}, \dots, x_{kn}) - y_k]^2 \quad (1)$$

مبنای ریاضی الگوریتم GMDH براساس تجزیه سری توابع ولتر⁸ به چند جمله‌ای‌های دو متغیره درجه دوم مطابق معادله (2) پایه‌ریزی شده است.

$$G(x_m, x_n) = a_0 + a_1 x_m + a_2 x_n + a_3 x_m x_n + a_4 x_m^2 + a_5 x_n^2 \quad (2)$$

ضرایب a_i (نشان داده شده در معادله (2)) به‌وسیله روش‌های مختلفی قابل محاسبه هستند. به‌گونه‌ای که اختلاف بین خروجی واقعی و خروجی تخمین زده شده برای هر دو جفت متغیر ورودی x_m و x_n حداقل شود [23,22]. یکی از روش‌های متداول جهت تعیین ضرایب شبکه‌های عصبی روش تجزیه مقادیر منفرد است که دارای الگوریتم عملکردی به شرح زیر است [24]:

مرحله نخست: ماتریس غیرمربعی A به‌صورت معادله (3) تعریف می‌شود:

$$A = \begin{bmatrix} 1 & x_{1i} & x_{1j} & x_{1i}x_{1j} & x_{1i}^2 & x_{1j}^2 \\ 1 & x_{2i} & x_{2j} & x_{2i}x_{2j} & x_{2i}^2 & x_{2j}^2 \\ \vdots & \vdots & \vdots & \vdots & \vdots & \vdots \\ 1 & x_{Mi} & x_{Mj} & x_{Mi}x_{Mj} & x_{Mi}^2 & x_{Mj}^2 \end{bmatrix} \quad (3)$$

که در آن، M تعداد مجموعه داده‌های آزمایشگاهی چند ورودی و تک خروجی است.

مرحله دوم: ماتریس A با استفاده از روش تجزیه مقادیر منفرد به‌صورت معادله (4) تجزیه می‌شود:

$$A = UVV^T \quad (4)$$

که در آن، ماتریس $A \in \mathbb{R}^{M \times 6}$ به‌صورت حاصل ضرب یک ماتریس ستونی متعامد $U \in \mathbb{R}^{M \times 6}$ در یک ماتریس قطری $V \in \mathbb{R}^{6 \times 6}$ با مقادیر نامنفی (مقادیر منفرد) بر روی قطر آن و ترانهاد یک ماتریس مربعی $V \in \mathbb{R}^{6 \times 6}$ تجزیه می‌شود.

مرحله سوم: ضرایب بهینه شبکه عصبی نوع GMDH با استفاده از معادله (5) تعیین می‌شود:

یکی از معروف‌ترین الگوریتم‌ها در جهت رفع نواقص مذکور استفاده از فیلتر کالمن است. فیلتر کالمن یک فیلتر بازگشتی کار است که متغیر حالت یک سیستم پویا را از دنباله‌ای از اندازه‌گیری‌های ناقص و مخدوش تخمین می‌زند. این فیلتر از یک سری مجموعه محاسبات برگشتی براساس حداقل نمودن میانگین مجذور خطای تخمین برای تخمین بهینه متغیرها و پارامترهای سیستم استفاده می‌نماید [8]. سینگال و وو از الگوریتم فیلتر کالمن توسعه یافته¹ جهت آموزش شبکه‌های عصبی پیشخور² استفاده نمودند. آن‌ها تمامی وزن‌های شبکه را تحت عنوان یک بردار متغیر حالت در الگوریتم فیلتر کالمن توسعه یافته در نظر گرفته و سپس نشان دادند که الگوریتم فیلتر کالمن توسعه یافته به تعداد تکرار کمتری نسبت به الگوریتم پس‌انتشار نیاز دارد و از دقت بالاتری برخوردار است [9]. اما هنگامی که تعداد نرون‌های مخفی افزایش می‌یابد، بعد بردار متغیر حالت (وزن‌های شبکه) و همچنین ماتریس کوواریانس خطا خیلی بزرگ می‌شود و اغلب سبب مشکل در محاسبات عددی می‌شود. جهت کاهش پیچیدگی محاسبات پاسکریوس و فلدکمپ الگوریتم فیلتر کالمن توسعه یافته مجزا³ را ارائه نمودند که در آن وزن‌های هر لایه به‌صورت مجزا تعیین می‌شود و با این کار بعد بردار متغیر حالت کاهش می‌یابد [10]. ریوالدز و پرسوناز، حالت‌های مختلف مقادیر اولیه برای الگوریتم آموزشی فیلتر کالمن توسعه یافته بررسی نمودند و سپس پیشنهاد نمودند که چگونه مقادیر اولیه را برای کوواریانس خطای سیستم و ماتریس خطای نویز فرآیند انتخاب شود [11]. وان در مرو از الگوریتم فیلتر کالمن آنسند⁴ جهت آموزش شبکه‌های عصبی استفاده نمود و نشان داد که الگوریتم فیلتر کالمن آنسند روشی پایدارتر و با نرخ همگرایی سریع‌تری نسبت به فیلتر کالمن توسعه یافته است [12,13].

وو و مراگلسکی از فیلترهای کالمن توسعه یافته و کالمن آنسند جهت آموزش شبکه‌های عصبی پیشخور استفاده نمودند و نشان دادند که مدل شبکه حاصله براساس فیلتر کالمن آنسند (در مواردی که سیستم دارای عناصر غیرخطی پیچیده است) از دقت پیش‌بینی بهتری نسبت به فیلتر کالمن توسعه یافته برخوردار است [14,15].

یکی از انواع شبکه‌های عصبی، که در شناسایی مدل و پیش‌بینی رفتار سیستم‌های خیلی پیچیده و یا نامعلوم مورد استفاده قرار می‌گیرد، الگوریتم دسته‌بندی گروهی داده‌ها⁵ است که توسط پروفیسور ابواخنینکو معرفی و گسترش پیدا کرده است [16]. در سال‌های اخیر، تلاش‌های زیادی در جهت شناسایی ساختار و ضرایب این شبکه‌ها توسط محققان انجام پذیرفته است و الگوریتم‌های تکاملی به‌خصوص الگوریتم ژنتیک به دفعات جهت شناسایی ساختار شبکه پیشنهاد شده است [17,18]. زیرا الگوریتم‌های تکاملی به‌ویژه برای مسایل پیچیده که دارای فضای جستجو با اکسترمم‌های محلی فراوان است کارایی بسیار دارند. همچنین، جهت تعیین ضرایب شبکه روش تجزیه مقادیر منفرد⁶ مورد استفاده قرار گرفته است [19,20].

در این مقاله از الگوریتم فیلتر کالمن آنسند به جای روش تجزیه مقادیر منفرد برای یافتن ضرایب شبکه عصبی نوع GMDH استفاده شده است. مدل‌سازی برای دو دسته داده ورودی-خروجی مربوط به فرآیند برشکاری انفجاری و فرآیند شکل‌دهی انفجاری آزاد انجام می‌شود و نشان

1- Extended Kalman Filter (EKF)

2- Feed Forward

3- Decoupled EKF

4- Unscented Kalman Filter (UKF)

5- Group Method Data Handling

6- Singular Value Decomposition (SVD)

7- Cybernetic
8- Volterra function

$$\chi_{i+L,k-1} = \hat{x}_{k-1} - (\sqrt{(L+\lambda)P_{k-1}})_i \quad (14)$$

$$\omega_0^{(m)} = \frac{\lambda}{(L+\lambda)} \quad (15)$$

$$\omega_0^{(c)} = \frac{\lambda}{(L+\lambda)} + (1 - \alpha^2 + \beta) \quad (16)$$

$$\omega_i^{(m)} = \omega_i^{(c)} = \frac{1}{2(L+\lambda)} \quad (17)$$

$$\lambda = \alpha^2(L + \kappa) - L \quad (18)$$

که در آن $i=1,2,\dots,L$ و L بعد بردار متغیر حالت است. χ_i بیانگر مقادیر نقاط سیگما است که براساس مقادیر میانگین $(\bar{x})$ و کوواریانس (P) بردار حالت در گام پیشین (x_{k-1}) محاسبه می‌گردند. $\omega_i^{(c)}$ و $\omega_i^{(m)}$ وزن‌های تبدیل آنستند مرتبط با i امین نقطه سیگما هستند. α و β ضرایب طراحی هستند که توسط طراح انتخاب می‌گردند. همچنین، κ مثبت نیمه معین بودن ماتریس کوواریانس را تضمین می‌نماید.

مرحله سوم: مقادیر میانگین و کوواریانس متغیرهای تخمین زده شده را می‌توان از طریق انتشار نقاط سیگما تعیین شده در معادلات (12) تا (18)، توسط مدل دینامیکی غیرخطی تعیین شده در معادلات (8) و (9)، به صورت معادلات (19) تا (22) به دست آورد.

$$\chi_{i,k|k-1} = f(\chi_{i,k-1}, u_k) \quad (19)$$

$$\hat{x}_k^- = \sum_{i=0}^{2L} \omega_i^{(m)} \chi_{i,k-1} \quad (20)$$

$$P_k^- = \sum_{i=0}^{2L} \omega_i^{(c)} [\chi_{i,k-1} - \hat{x}_k^-][\chi_{i,k-1} - \hat{x}_k^-]^T \quad (21)$$

$$\hat{y}_k^- = \sum_{i=0}^{2L} \omega_i^{(m)} h(\chi_{i,k-1}) \quad (22)$$

که در آن $\hat{x}_k^-$ و $\hat{y}_k^-$ مقادیر میانگین تخمین زده شده از قبل x و y در لحظه k هستند.

مرحله چهارم: مقادیر مشاهده گر تخمین زده و به روز رسانی ماتریس‌های کوواریانس به وسیله معادلات (23) تا (27) به دست می‌آیند.

$$P_{k|k-1}^{yy} = \sum_{i=0}^{2L} \omega_i^{(c)} [h(\chi_{i,k-1}) - \hat{y}_k^-][h(\chi_{i,k-1}) - \hat{y}_k^-]^T \quad (23)$$

$$P_{k|k-1}^{xy} = \sum_{i=0}^{2L} \omega_i^{(c)} [\chi_{i,k-1} - \hat{x}_k^-][h(\chi_{i,k-1}) - \hat{y}_k^-]^T \quad (24)$$

$$K_k = (P_{k|k-1}^{xy}) (P_{k|k-1}^{yy})^{-1} \quad (25)$$

$$\hat{x}_k = \hat{x}_k^- + K_k (y_k - \hat{y}_k^-) \quad (26)$$

$$P_k = P_k^- - K_k P_{k|k-1}^{yy} K_k^T \quad (27)$$

که در آن به ترتیب P^{yy} ، P^{xy} و K_k نشان‌دهنده مقادیر کوواریانس‌های خطای y خطای بین بردارهای حالت و مشاهده گر و پارامتر تصحیح کالمن هستند.

4- کاربرد فیلتر کالمن آنستند در تخمین ضرایب شبکه عصبی نوع GMDH

این بخش به تخمین پارامترهای یک مدل غیرخطی $y_k = g(x_k, a)$ اختصاص یافته است که در آن x_k و y_k به ترتیب بردار داده‌های ورودی و خروجی هستند [12]. مدل غیرخطی $g(\cdot)$ ، همان مدل درجه دوم شبکه GMDH است که براساس ضرایب شبکه (a) به صورت پارامتری نشان داده شده است.

$$a = V[\text{diag}\left(\frac{1}{w_j}\right)]U^T Y \quad (5)$$

قابل ذکر است که در تعیین معکوس ماتریس قطری W ، معکوس عناصر صفر یا تکیه‌های نزدیک به صفر برابر صفر قرار داده می‌شود.

1-2- شناسایی ساختار شبکه عصبی نوع GMDH

روش‌های گوناگونی جهت شناسایی ساختار شبکه عصبی نوع GMDH توسط محققان ارائه شده است. در این مقاله، روش دوم ارائه شده در مقاله [16] جهت تعیین ساختار شبکه مورد استفاده قرار می‌گیرد. در این روش تعداد لایه‌ها (N_l) و همچنین تعداد نرون‌های هر لایه از قبل مشخص شده است و مراحل اصلی این روش را می‌توان به صورت زیر توصیف نمود:

مرحله نخست: تعداد نرون‌های لایه اول (N_1) برابر تعداد ورودی‌ها (n) قرار داده شود و $k=1$ در نظر گرفته شود.

مرحله دوم: تعداد N' نرون جدید براساس همه احتمالات ممکن بین هر دو جفت نرون موجود در لایه $(\text{معادله } (6))$ با استفاده از چندجمله‌ای درجه دوم $G(x_m, x_n)$ ذکر شده در معادله (2) تولید شود.

$$N'_k = \frac{N_k(N_k - 1)}{2} \quad (6)$$

مرحله سوم: بهترین N_{k+1} نرون (که از قبل توسط طراح مشخص شده است) از میان N'_k نرون تولید شده در گام دوم براساس مقدار تابع r^2 به دست آمده از معادله (7) انتخاب شود.

$$r^2 = \frac{\sum_{i=1}^M (y_i - G_i(\cdot))^2}{\sum_{i=1}^M y_i^2} \quad (7)$$

مرحله چهارم: اگر $k+1 \neq N_l$ باشد آنگاه $k=k+1$ قرار داده و $N_k = N_{k-1}$ در نظر گرفته شود و به مرحله دوم مراجعه شود. در غیر این صورت الگوریتم به اتمام می‌رسد.

به این نکته توجه شود که در لایه آخر فقط یک نرون انتخاب می‌شود.

3- فیلتر کالمن آنستند

معادلات غیرخطی زمان گسسته یک سیستم دینامیکی را می‌توان به صورت معادله (8) و (9) توصیف نمود [12]:

$$x_{k+1} = f(x_k, u_k) + w_k \quad (8)$$

$$y_k = h(x_k) + v_k \quad (9)$$

که در آن x_k بیانگر بردار متغیرهای حالت نامعلوم سیستم u_k بیانگر ورودی خارجی معلوم و y_k نیز بیانگر سیگنال قابل اندازه‌گیری است. نویز فرآیند w_k از دینامیک سیستم ناشی شده و نویز مشاهده گر v_k ناشی از عدم قطعیت داده‌های ثبت شده توسط مشاهده گر است. نویزهای فرآیند و مشاهده گر هر دو گوسی سفید بوده و دارای کوواریانس‌های به ترتیب Q_k و R_k هستند.

الگوریتم عملکردی فیلتر کالمن شامل 4 مرحله است که عبارت‌اند از:

مرحله نخست: تخمین مقادیر بردار حالت اولیه $(\hat{x}_0)$ و کوواریانس خطای اولیه (P_0) مطابق روابط (10) و (11) تخمین زده می‌شود:

$$\hat{x}_0 = E[x_0] \quad (10)$$

$$P_0 = E[(x_0 - \hat{x}_0)(x_0 - \hat{x}_0)^T] \quad (11)$$

مرحله دوم: محاسبه نقاط سیگما و وزن‌های تبدیل فیلتر کالمن آنستند مطابق روابط (12) تا (18) محاسبه می‌شود:

$$\chi_{0,k-1} = \hat{x}_{k-1} \quad (12)$$

$$\chi_{i,k-1} = \hat{x}_{k-1} + (\sqrt{(L+\lambda)P_{k-1}})_i \quad (13)$$

که در آن کوواریانس نویز R_e یک ماتریس قطری ثابت است که می‌توان آن را به صورت اختیاری انتخاب نمود (به عنوان مثال $R_e = \frac{1}{2}$) [12]. همچنین، R_r کوواریانس نویز فرآیند است که توسط تقریب رابینسون مونرو (نشان داده شده در معادله (46)) مشخص می‌شود:

$$R_{r,k} = (1 - \alpha_{RM})R_{r,k-1} + \alpha_{RM}K_k[d_k - g(x_k; \hat{a}_k^-)]^T K_k \quad (46)$$

5- نتایج شبیه‌سازی

در این بخش از روش پیشنهادی برای مدل‌سازی دو دسته داده آزمایشگاهی چند ورودی و تک خروجی استفاده شده است. مقایسه نتایج با روش تجزیه مقادیر منفرد نشان‌دهنده برتری و عملکرد مقاوم‌تر روش پیشنهادی است.

5-1- فرآیند برشکاری انفجاری

نتایج آزمایشگاهی برای فرآیند برشکاری انفجاری در جدول 1 مشاهده می‌شود [25]. این جدول شامل 43 مورد آزمایش است که هر مورد از آزمایش شامل چهار پارامتر ورودی زاویه نوک، فاصله خرج انفجاری تا صفحه، وزن انفجاری و ضخامت خطی و تک خروجی (عمق نفوذ) است. بنابراین، بردار ورودی X به صورت $X = \{AA, S, EW, LT\}$ نمایش داده می‌شود که در آن علائم AA, S, EW و LT به ترتیب مربوط به پارامترهای زاویه نوک، فاصله خرج انفجاری تا صفحه، وزن انفجاری و ضخامت خطی هستند که در شکل 1 نمایش داده شده‌اند.

از 43 نمونه آزمایشی 30 نمونه جهت آموزش شبکه و 13 نمونه بعدی جهت بررسی قدرت پیش‌بینی مدل مورد استفاده قرار گرفته است. ساختار شبکه عصبی نوع GMDH و تعداد نرون‌های هر لایه برای فرآیند برشکاری انفجاری با چهار ورودی و یک خروجی به صورت [1, 2, 3, 4] فرض شده است [1]. با استفاده از فیلتر کالمن آنسنتد و روش تجزیه مقادیر منفرد ضرایب شبکه عصبی نوع GMDH برای داده‌های کاملاً معین و بدون نامعینی تعیین می‌شود. رفتار مدل شبکه‌های عصبی تولید شده به وسیله نامعینی تعیین می‌شود. رفتار مدل شبکه‌های عصبی تولید شده به وسیله فیلتر کالمن آنسنتد و روش تجزیه مقادیر منفرد در مقایسه با مقادیر واقعی در شکل 2 نشان داده شده است. همچنین، در جدول 2 مقادیر خطاهای آموزش و پیش‌بینی مدل‌های شبکه عصبی با دو روش کالمن آنسنتد و تجزیه مقادیر منفرد در فرآیند برشکاری انفجاری برای داده‌های معین مقایسه شده است. با بررسی شکل 2 و جدول 2 می‌توان مشاهده نمود که مقادیر خطاهای آموزش و پیش‌بینی در مدل شبکه عصبی نوع GMDH ایجاد شده با روش تجزیه مقادیر منفرد برای جدول داده‌های آزمایشگاهی بدون نامعینی بهتر از مقادیر این خطاها برای مدل ایجاد شده با استفاده از فیلتر کالمن آنسنتد است.

اما در کاربردهای مهندسی واقعی، معمولاً داده‌های آزمایشگاهی با نویز مخدوش بوده و دارای عدم قطعیت به دلایل مختلف از جمله خطای انسانی و ابزارهای اندازه‌گیری است. به عنوان مثال، در جدول 1 برای آزمایش اول زاویه نوک برابر 45 درجه اندازه‌گیری شده است، اما به دلیل عوامل متعدد از جمله خطای ابزار، خطای انسانی و حتی دمای محیط این مقدار می‌تواند دارای خطا باشد ($5\% \pm$). بنابراین، در مدل‌سازی براساس داده‌های ورودی و خروجی باید نامعینی‌های موجود در این داده‌های آزمایشگاهی در نظر گرفته شوند. برای در نظر گرفتن این نامعینی تابع توزیع گوسی که میانگین برابر با مقدار اندازه‌گیری شده آن پارامتر و واریانس برابر با 10% دارد در نظر گرفته

هدف از آموزش تعیین ضرایب شبکه به گونه ای است که مجذور مربعات خطای شبکه حداقل شود که در آن تابع خطای شبکه به صورت معادله (28) تعریف می‌شود:

$$e_k = d_k - g(x_k; a) \quad (28)$$

و d_k خروجی مطلوب است.

با توجه به ساختار غیرخطی شبکه عصبی نوع GMDH بهتر است برای آموزش ضرایب شبکه بر مبنای داده‌های اندازه‌گیری شده مخدوش با نویز از یک فیلتر غیرخطی استفاده شود. فیلترهای کالمن توسعه یافته و آنسنتد از متداول‌ترین فیلترهای غیرخطی مورد استفاده توسط محققان جهت تخمین پارامترهای سیستم دینامیکی هستند. از آنجایی که فیلتر کالمن توسعه یافته به دلیل خطی‌سازی از دقت کمتری نسبت به فیلتر کالمن آنسنتد برخوردار است. در این مقاله استفاده از فیلتر کالمن آنسنتد توصیه شده است [14].

الگوریتم کاربردی فیلتر کالمن آنسنتد در جهت تخمین ضرایب شبکه عصبی نوع GMDH را می‌توان به صورت زیر توصیف نمود:

مرحله نخست: تخمین بردار ضرایب اولیه ($\hat{a}_0$) و ماتریس کوواریانس خطای اولیه (P_0) مطابق روابط (29) و (30) تخمین زده می‌شود:

$$\hat{a}_0 = E[a_0] \quad (29)$$

$$P_0 = E[(a_0 - \hat{a}_0)(a_0 - \hat{a}_0)^T] \quad (30)$$

مرحله دوم: به روز رسانی زمانی مقادیر ضرایب شبکه و کوواریانس خطا مطابق روابط (31) و (32) به روز رسانی زمانی می‌شود:

$$\hat{a}_k^- = \hat{a}_{k-1} \quad (31)$$

$$P_{a,k}^- = P_{a,k-1} + R_{r,k-1} \quad (32)$$

مرحله سوم: محاسبه مقادیر نقاط سیگما و وزن‌های تبدیل آنسنتد مطابق روابط (33) تا (38) محاسبه می‌شود:

$$\chi_{0,k-1} = \hat{a}_k^- \quad (33)$$

$$\chi_{i,k-1} = \hat{a}_k^- + (\sqrt{(L + \lambda)P_{a,k}^-})_i \quad (34)$$

$$\chi_{i+L,k-1} = \hat{a}_k^- - (\sqrt{(L + \lambda)P_{a,k}^-})_i \quad (35)$$

$$\omega_0^{(m)} = \frac{\lambda}{(L + \lambda)} \quad (36)$$

$$\omega_0^{(c)} = \frac{\lambda}{(L + \lambda)} + (1 - \alpha^2 + \beta) \quad (37)$$

$$\omega_i^{(m)} = \omega_i^{(c)} = \frac{1}{2(L + \lambda)} \quad (38)$$

مرحله چهارم: به روز رسانی مقادیر اندازه‌گیری شده مطابق روابط (39) تا (45) به روز رسانی زمانی می‌شود:

$$y_{k|k-1} = g(x_k, \chi_{i,k-1}) \quad (39)$$

$$\hat{d}_k^- = \sum_{i=0}^{2L} \omega_i^{(m)} y_{i,k|k-1} \quad (40)$$

$$P_{\hat{d}_k} = \sum_{i=0}^{2L} \omega_i^{(c)} [y_{i,k|k-1} - \hat{d}_k^-][y_{i,k|k-1} - \hat{d}_k^-]^T + R_{e,k} \quad (41)$$


$$P_{a,k} = \sum_{i=0}^{2L} \omega_i^{(c)} [\chi_{i,k|k-1} - \hat{w}_k^-][y_{i,k|k-1} - \hat{d}_k^-]^T \quad (42)$$

$$K_k = P_{w_k a_k} P_{\hat{d}_k}^{-1} \quad (43)$$

$$\hat{a}_k = \hat{a}_k^- + K_k(d_k - \hat{d}_k^-) \quad (44)$$

$$P_{a,k} = P_{a,k}^- - K_k P_{\hat{d}_k} K_k^T \quad (45)$$


می‌شود. بنابراین، در این مرحله هیچ کدام از داده‌ها دارای قطعیت نیستند و نامعینی ذاتی موجود در آن‌ها برای مدل‌سازی لحاظ می‌شوند. به منظور بررسی رفتار دو مدل شبکه عصبی نوع GMDH تولید شده به وسیله روش‌های فیلتر کالمن آنستند و تجزیه مقادیر منفرد برای داده‌های دارای نامعینی 500 جدول به صورت تصادفی با استفاده از روش مونت کارلو و با توجه به توزیع احتمالاتی گوسی تولید می‌شوند. برای تمامی جداول تولید شده تصادفی مقادیر خطاهای آموزش و پیش‌بینی محاسبه شده و خطاهای هر جدول در شکل 3 نمایش داده شده است. همچنین، مقادیر میانگین و واریانس خطای مدل به‌ازای 500 جدول احتمالاتی در جدول 3 مشاهده می‌شوند.



شکل 2 مقایسه مقادیر واقعی با مقادیر به‌دست آمده از مدل‌های شبکه عصبی با دو روش UKF و SVD در فرآیند برشکاری انفجاری (داده‌های معین)

جدول 2 مقایسه مقادیر خطاهای آموزش و پیش‌بینی مدل‌های شبکه عصبی با دو روش UKF و SVD در فرآیند برشکاری انفجاری

مجموع خطاها	مقدار خطای پیش-بینی (PE)	مقدار خطای آموزش (TE)	روش شناسایی ضرایب شبکه
0/1965	0/11969	0/07681	SVD
0/36685	0/21213	0/15472	UKF




شکل 3 مجموع خطاهای آموزش و پیش‌بینی برای دو مدل حاصل از روش‌های UKF و SVD برای 500 جدول احتمالاتی در فرآیند برشکاری انفجاری

جدول 3 مقایسه مقادیر میانگین و واریانس خطای مدل حاصل از روش‌های UKF و SVD برای 500 جدول احتمالاتی در فرآیند برشکاری انفجاری

روش شناسایی ضرایب شبکه	میانگین خطاهای مدل	واریانس خطاهای مدل
شبکه عصبی	0/3453	0/008497
شبکه عصبی	0/3557	0/0006668

جدول 1 داده‌های آزمایشگاهی در یک فرآیند برشکاری انفجاری					
شماره نمونه	زاویه نوک (درجه)	فاصله خرج انفجاری تا انفجاری تا	وزن انفجاری (گرم)	ضخامت خطی (میلیمتر)	خروجی
1	45	0	50	0/9	2/4
2	60	0	50	0/9	3/1
3	75	0	50	0/9	4/7
4	90	0	50	0/9	6/1
5	100	0	50	0/9	8/2
6	120	0	50	0/9	5/4
7	135	0	50	0/9	4/7
8	100	-0/4	50	0/9	7
9	100	-0/2	50	0/9	8/2
10	100	0/2	50	0/9	8/25
11	100	1	50	0/9	7/8
12	100	0	50	1/38	8/3
13	100	0	50	1/26	8/3
14	100	0	50	1	9/3
15	100	0	50	0/61	7/1
16	100	0	50	0/35	6
17	100	0	150	2/4	16/3
18	100	0	150	1/5	16
19	100	0	150	1/05	13/1
20	100	0	150	0/83	11/1
21	100	0	250	3	21/9
22	100	0	250	2/81	22/2
23	100	0	250	2/52	21/2
24	100	0	250	1/9	22/4
25	100	0	250	1/36	21/5
26	100	0	12/25	0/4	2
27	100	0	50	0/9	9
28	100	0	150	1/5	16/1
29	100	0	250	1/9	22/4
30	100	0	300	2	25
31	95	0	50	0/9	8
32	105	0	50	0/9	7/1
33	100	0	50	0/9	9/05
34	100	0/4	50	0/9	8/25
35	100	0	50	1/13	9/3
36	100	0	50	0/74	6/9
37	100	0	50	0/48	5/9
38	100	0	150	1/95	17/1
39	100	0	150	0/6	10/3
40	100	0	250	2/23	21/9
41	100	0	250	1/65	22/4
42	100	0	100	1/2	12/1
43	100	0	200	1/7	19/6



شکل 1 پارامترهای ورودی در فرآیند برشکاری انفجاری

فیلتر کالمن آنستند کمتر از 0/1 واریانس شبکه عصبی به‌دست آمده با روش تجزیه مقادیر منفرد است. بنابراین، با وجود خطای کم مدل حاصل از روش تجزیه مقادیر منفرد برای داده‌های معین، نامعینی موجود در داده‌ها روی این مدل بسیار تاثیرگذار است و خطای مدل را افزایش و قدرت پیش‌بینی آن را کاهش می‌دهد، اما مدل حاصل از روش فیلتر کالمن آنستند رفتار مقاومی در مقابل نامعینی دارد و قدرت پیش‌بینی آن با وجود نامعینی کاهش نمی‌یابد.

5-2- فرآیند شکل‌دهی انفجاری آزاد ورق

تعیین مقدار کرنش محیطی در فرآیند شکل‌دهی انفجاری آزاد ورق به‌عنوان دومین مورد مطالعاتی در این مقاله مورد بررسی قرار گرفته است. نتایج حاصل از آزمایش‌ها در جدول 4 ارائه شده است [1]. همان‌طور که مشاهده


از شکل 3 مشاهده می‌شود که مجموع خطای آموزش و پیش‌بینی برای مدل به‌دست آمده با روش تجزیه مقادیر منفرد برای برخی جداول به حدود 0/85 می‌رسد (این مقدار برای جدول داده‌های دارای قطعیت مطابق جدول 1 حدود 0/19 است). این بدان معنی است که اگر داده‌های آزمایشگاهی حدود 10% نامعینی داشته باشند، خطای شبکه عصبی حدود چهار برابر می‌شود، اما برای مدل به‌دست آمده توسط فیلتر کالمن آنستند مطابق شکل 2، خطا حداکثر به 0/43 می‌رسد که در مقایسه با جدول داده‌های معین (0/36) حدود 1/2 برابر افزایش داشته است که نشان‌دهنده رفتار مقاوم این مدل در مقابل نامعینی موجود در داده‌هاست. با توجه به جدول 3 نیز می‌توان این موضوع را دریافت، زیرا واریانس خطای شبکه عصبی به‌دست آمده با روش

جدول 4 داده‌های آزمایشگاهی در یک فرآیند شکل‌دهی انفجاری آزاد ورق

شماره آزمایش	تنش تسلیم دینامیکی	ضخامت ورق	میزان خرج انفجاری	خیز مرکز ورق	فاصله از مرکز ورق	کرنش محیطی	شماره آزمایش	تنش تسلیم دینامیکی	ضخامت ورق	میزان خرج انفجاری	خیز مرکز ورق	فاصله از مرکز ورق	کرنش محیطی
1	18/8	0/036	30	1/75	1	0/248	42	16/1	0/036	24	1/49	5	0/0224
2	18/8	0/036	30	1/75	3	0/1296	43	16/1	0/036	12	1	1	0/0592
3	18/8	0/036	30	1/75	5	0/056	44	16/1	0/036	12	1	3	0/0336
4	18/8	0/036	24	1/65	1	0/1792	45	16/1	0/036	12	1	5	0/0064
5	18/8	0/036	24	1/65	3	0/104	46	18/3	0/08	45	1/31	1	0/1008
6	18/8	0/036	24	1/65	5	0/04	47	18/3	0/08	45	1/31	3	0/0672
7	18/8	0/036	12	1/12	1	0/0928	48	18/3	0/08	45	1/31	5	0/0192
8	18/8	0/036	12	1/12	3	0/056	49	18/3	0/08	12	1/31	1	0/0192
9	18/8	0/036	12	1/12	5	0/016	50	18/3	0/08	12	1/31	3	0/016
10	18/3	0/08	64	1/56	1	0/1648	51	18/3	0/08	12	1/31	5	0/0048
11	18/3	0/08	64	1/56	3	0/104	52	15/8	0/064	72	1/57	1	0/1984
12	18/9	0/08	64	1/56	5	0/032	53	15/8	0/064	72	1/57	3	0/1008
13	18/3	0/08	36	1/21	1	0/096	54	15/8	0/064	72	1/57	5	0/024
14	18/3	0/08	36	1/21	3	0/064	55	15/8	0/064	60	1/45	1	0/1344
15	18/3	0/08	36	1/21	5	0/016	56	15/8	0/064	60	1/45	3	0/0752
16	15/5	0/036	12	1/35	1	0/152	57	15/8	0/064	60	1/45	5	0/016
17	15/5	0/036	12	1/35	3	0/08	58	15	0/048	48	1/71	1	0/224
18	15/5	0/036	12	1/35	5	0/0272	59	15	0/048	48	1/71	3	0/1104
19	15/5	0/036	6	0/96	1	0/064	60	15	0/048	48	1/71	5	0/304
20	15/5	0/036	6	0/96	3	0/0368	61	15	0/048	12	0/78	1	0/04
21	15/5	0/036	6	0/96	5	0/0096	62	15	0/048	12	0/78	3	0/024
22	16/3	0/08	72	1/953	2	0/224	63	15	0/048	12	0/78	5	0/0048
23	16/3	0/08	72	1/953	3	0/144	64	13	0/036	36	1/63	1	0/1584
24	16/3	0/08	72	1/953	5	0/0368	65	13	0/036	36	1/63	3	0/0832
25	16/3	0/08	36	1/42	1	0/1472	66	13	0/036	36	1/63	5	0/024
26	16/3	0/08	36	1/42	3	0/096	67	13	0/036	9	0/71	1	0/04
27	16/3	0/08	36	1/42	5	0/0256	68	13	0/036	9	0/71	3	0/0224
28	8/88	0/036	5/5	1/25	1	0/1488	69	13	0/036	9	0/71	5	0/0064
29	8/88	0/036	5/5	1/25	3	0/08	70	19/4	0/036	72	1/95	1	0/1936
30	8/88	0/036	5/5	1/25	5	0/024	71	19/4	0/036	72	1/95	3	0/12
31	8/88	0/036	2	0/81	1	0/056	72	19/4	0/036	72	1/95	5	0/028
32	8/88	0/036	2	0/81	3	0/032	73	19/4	0/036	36	1/57	1	0/1248
33	8/88	0/036	2	0/81	5	0/0096	74	19/4	0/036	36	1/57	3	0/08
34	7/77	0/08	18	1/59	1	0/2096	75	19/4	0/036	36	1/57	5	0/0224
35	7/77	0/08	18	1/59	3	0/112	76	26/1	0/036	48	1/33	1	0/1024
36	7/77	0/08	18	1/59	5	0/0352	77	26/1	0/036	48	1/33	3	0/0512
37	7/77	0/08	8	0/92	1	0/0752	78	26/1	0/036	48	1/33	5	0/0032
38	7/77	0/08	8	0/92	3	0/0448	79	26/1	0/036	24	0/91	1	0/04
39	7/77	0/08	8	0/92	5	0/0144	80	26/1	0/036	24	0/91	3	0/0192
40	16/1	0/036	24	1/49	1	0/1776	81	26/1	0/036	24	0/91	5	-0/004
41	16/1	0/036	24	1/49	3	0/0848							

جدول 5 مقایسه مقادیر خطاهای آموزش و پیش‌بینی مدل‌های شبکه عصبی با دو روش UKF و SVD در فرآیند شکل‌دهی انفجاری آزاد ورق

روش شناسایی	مقدار خطای آموزش (TE)	مقدار خطای پیش-بینی (PE)	مجموع خطاها
SVD	0/0026783	0/036367	0/0390453
UKF	0/0035768	0/038875	0/0424518



شکل 5 مقایسه مجموع خطای آموزش و پیش‌بینی برای دو مدل حاصل از روش‌های UKF و SVD برای 500 جدول احتمالاتی در فرآیند شکل‌دهی انفجاری آزاد ورق

جدول 6 مقایسه مقادیر میانگین و واریانس خطای مدل حاصل از دو روش UKF و SVD برای 500 جدول احتمالاتی در فرآیند شکل‌دهی انفجاری آزاد ورق

روش شناسایی	میانگین خطاهای مدل	واریانس خطاهای مدل
ضرایب شبکه	شبکه عصبی	شبکه عصبی
SVD	0/29695	0/072579
UKF	0/10082	0/008253

مدل ناشی از شبکه عصبی GMDH با روش تجزیه مقادیر منفرد است. که این موضوع نیز گواهی بر پایداری بیشتر و مقاوم‌تر بودن مدل شبکه عصبی GMDH با فیلتر کالمن آنسنتد در برابر عدم قطعیت داده‌های اندازه‌گیری شده است.

6- نتیجه‌گیری

در این مقاله از فیلتر کالمن آنسنتد برای تعیین ضرایب چندجمله‌ای‌های شبکه عصبی نوع GMDH برای دو دسته داده آزمایشگاهی استفاده شده است. با استفاده از این روش، ضرایب بر روی جدول داده‌های آزمایشگاهی بدون در نظر گرفتن نامعینی به‌دست آمدند و برای بررسی مقاوم بودن مدل به‌دست آمده در برابر نامعینی‌های موجود در داده‌ها از روش مونت کارلو استفاده شد. مقایسه نتایج با روش تجزیه مقادیر منفرد نشان‌دهنده رفتار مقاوم‌تر مدل به‌دست آمده از روش فیلتر کالمن آنسنتد است. برای هر دو دسته داده آزمایشگاهی با وجود نامعینی مقدار واریانس خطا برای مدل به‌دست آمده با روش فیلتر کالمن آنسنتد حدود 0/1 واریانس خطا برای مدل به‌دست آمده از روش تجزیه مقادیر منفرد تعیین شد.

7- مراجع


- [1] G. R. Ahmad Zadeh, GMDH-Type Neural Network Modelling of Explosive Cutting Process of Plates, M.S. Thesis, Department of Mechanical Engineering, University of Guilan, 2003. (In Persian)
- [2] N. Narimanzadeh, A. Darvizeh, G. R. Ahmad Zadeh, Hybrid genetic design of GMDH-type neural networks using singular value decomposition for modelling and prediction of the explosive cutting process, *Proceedings of*

می‌شود این جدول در برگزیده 81 دسته داده آزمایش است. دارای 5 پارامتر ورودی شامل تنش تسلیم دینامیکی، ضخامت ورق، میزان خرج انفجاری، خیز مرکز ورق و فاصله از مرکز ورق و کرنش محیطی به‌عنوان خروجی است. از 81 نمونه آزمایش 60 نمونه جهت آموزش شبکه و 21 نمونه جهت بررسی قدرت پیش‌بینی مدل تولید شده توسط شبکه عصبی نوع GMDH مورد استفاده قرار گرفته است. ساختار شبکه عصبی نوع GMDH و تعداد نرون‌ها در هر لایه به‌صورت [1, 2, 4, 5, 6] در نظر گرفته شده است [1].

در این مرحله همانند فرآیند برشکاری انفجاری، ضرایب شبکه عصبی GMDH برای داده‌های معین با استفاده از دو روش فیلتر کالمن آنسنتد و تجزیه مقادیر منفرد تعیین می‌شود.

نتایج خطاهای آموزش و پیش‌بینی ناشی از مدل‌های شبکه عصبی به‌دست آمده از روش‌های فیلتر کالمن آنسنتد و تجزیه مقادیر منفرد در جدول 5 و شکل 4 نشان داده شده است. این نتایج به‌وضوح نشان می‌دهند برای داده‌های آزمایشگاهی معین بزرگی خطاهای آموزش و پیش‌بینی برای مدل‌های حاصل از دو روش مورد نظر در این مقاله (روش تجزیه مقادیر منفرد و فیلتر کالمن آنسنتد) تقریباً با یکدیگر یکسان است. (قابل ذکر است مقدار خطاهای ناشی از روش تجزیه مقادیر منفرد به مقدار ناچیزی از خطاهای ناشی از روش فیلتر کالمن آنسنتد بهتر است).

به منظور بررسی رفتار مدل‌های به‌دست آمده به‌وسیله روش‌های تجزیه مقادیر منفرد و فیلتر کالمن آنسنتد در مقابل نامعینی‌های مدل و وسایل اندازه‌گیری، مجدداً از 500 جدول تصادفی تولید شده با استفاده از روش مونت کارلو با 10 درصد توزیع احتمالاتی گوسی استفاده می‌شود. مقدار مجموع خطای آموزش و پیش‌بینی دو مدل حاصل از روش‌های فیلتر کالمن آنسنتد و تجزیه مقادیر منفرد برای تمامی جداول تصادفی تولید شده با استفاده از روش مونت کارلو محاسبه شده و در شکل 5 و جدول 6 نمایش داده شده است. با دقت در شکل 5 مشاهده می‌شود که مقدار مجموع خطاهای آموزش و پیش‌بینی مدل شبکه عصبی با روش تجزیه مقادیر منفرد تا مقدار 1/6 (یعنی تقریباً چهل برابر مقدار مجموع خطاها برای جدول داده‌های معین نشان داده شده در جدول 5) افزایش می‌یابد؛ در حالی که برای مدل شبکه عصبی با فیلتر کالمن آنسنتد، مقدار خطای جداول تصادفی به 0/46 می‌رسد که تقریباً 25% مقدار مجموع خطاهای آموزش و پیش‌بینی مدل حاصل از تجزیه مقادیر منفرد است. همچنین، جدول 6 به این موضوع اشاره دارد که مقدار خطاهای آموزش و پیش‌بینی مدل ناشی از شبکه عصبی GMDH با فیلتر کالمن آنسنتد دارای میانگین و واریانس به مراتب کمتر از



شکل 4 مقایسه مقادیر واقعی با مقادیر به‌دست آمده از مدل‌های شبکه عصبی با دو روش UKF و SVD در فرآیند شکل‌دهی انفجاری آزاد ورق (داده‌های معین)

- [15] M. Mrugalski, An unscented Kalman filter in designing dynamic GMDH neural networks for robust fault detection, *International Journal of Applied Mathematics and Computer Science*, Vol. 1, pp. 157-169, 2013.
- [16] A. Darvizeh, N. Nariman Zadeh, H. Gharababaei, GMDH-Type neural network modelling of explosive cutting process of plates using singular value decomposition, *Systems Analysis Modelling Simulation*, Vol. 43, No. 10, pp. 1383-1397, 2003.
- [17] N. Narimanzadeh, A. Darvizeh, M. Darvizeh, H. Gharababaei, Modelling of explosive cutting process of plates using GMDH-type neural network and singular value decomposition, *Journal of Materials Processing Technology*, Vol. 128, No. 1-3, pp. 80-87, 2002.
- [18] H. Ghanadzadeh, M. Ganji, S. Fallahi, Mathematical model of liquid-liquid equilibrium for a ternary system using the GMDH-type neural network and genetic algorithm, *Applied Mathematical Modelling*, Vol. 36, No. 9, pp. 4096-4105, 2012.
- [19] S. C. Satapathy, S. Chittineni, S. Mohan Krishna, J. V. R. Murthy, P. V. G. D. Prasad Reddy, Kalman particle swarm optimized polynomials for data classification, *Applied Mathematical Modelling*, Vol. 36, No. 1, pp. 115-126, 2012.
- [20] R. Mohanty, V. Ravi, M. R. Patra, Hybrid intelligent systems for predicting software reliability, *Applied Soft Computing*, Vol. 13, No. 1, pp. 189-200, 2013.
- [21] A. Jamali, N. Narimanzadeh, A. Darvizeh, A. Masoumi, S. Hamrang, Multi-objective evolutionary optimization of polynomial neural networks for modelling and prediction of explosive cutting process, *Engineering Applications of Artificial Intelligence*, Vol. 22, No. 4-5, pp. 676-687, 2009.
- [22] T. Kondo, J. Ueno, S. Takao, Hybrid Multi-layered GMDH-type Neural Network Using Principal Component Regression Analysis and its Application to Medical Image Diagnosis of Liver Cancer, *Procedia Computer Science*, Vol. 22, No. 0, pp. 172-181, 2013.
- [23] S. Abdolrahimi, B. Nasernejad, G. Pazuki, Prediction of partition coefficients of alkaloids in ionic liquids based aqueous biphasic systems using hybrid group method of data handling (GMDH) neural network, *Journal of Molecular Liquids*, Vol. 191, No. 0, pp. 79-84, 2014.
- [24] N. Nariman Zadeh, A. Darvizeh, M. E. Felezi, H. Gharababaei, Polynomial modelling of explosive compaction process of metallic powders using GMDH-type neural networks and singular value decomposition, *Modelling and Simulation in Materials Science and Engineering*, Vol. 10, pp. 727-735, 2002.
- [25] S. A. L. Salem, S. T. S. Al Hassani, Penetration by high speed oblique jets: Theory and experiment, *International Journal of Mechanical Sciences*, Vol. 25, No. 12, pp. 871-886, 1983.
- [3] S. C. Stubberud, System Identification using the Neural-Extended Kalman Filter for Control Modification, in *Proceeding of International Joint Conference on Neural Networks*, pp. 4449-4455, 2006.
- [4] H. Yang, J. Li, F. Ding, A neural network learning algorithm of chemical process modeling based on the extended Kalman filter, *Neurocomputing*, Vol. 70, No. 4-6, pp. 625-632, 2007.
- [5] N. Srinivasan, V. Ravichandran, K. L. Chan, J. R. Vidhya, S. Ramakrishnan, S. M. Krishnan, Exponentiated backpropagation algorithm for multilayer feedforward neural networks, in *Proceeding of the 9th International Conference on Neural Information Processing*, pp. 327-331, 2002.
- [6] S. C. Ng, C. C. Cheung, S. H. Leung, A. Luk, Fast convergence for backpropagation network with magnified gradient function, in *Proceeding of the International Joint Conference on Neural Networks*, pp. 1903-1908, 2003.
- [7] J. de Jesús Rubio, W. Yu, Nonlinear system identification with recurrent neural networks and dead-zone Kalman filter algorithm, *Neurocomputing*, Vol. 70, No. 13-15, pp. 2460-2466, 2007.
- [8] R. E. Kalman, A new approach to linear filtering and prediction problems, *ASME Journal of Basic Engineering*, Vol. 82, pp. 35-45, 1960.
- [9] S. Singhal, L. Wu, Training feed-forward networks with the extended Kalman algorithm, in *Proceeding of the International Conference on Acoustics, Speech, and Signal Processing*, pp. 1187-1190, 1989.
- [10] G. V. Puskorius, L. A. Feldkamp, Decoupled extended Kalman filter training of feedforward layered networks, in *Proceeding of International Joint Conference on Neural Networks*, pp. 771-777, 1991.
- [11] I. Rivals, L. Personnaz, A recursive algorithm based on the extended Kalman filter for the training of feedforward neural models, *Neurocomputing*, Vol. 20, No. 1-3, pp. 279-294, 1998.
- [12] R. V. D. Merwe, *Sigma-Point Kalman Filters for Probabilistic Inference in Dynamic State-Space Models*, PhD Thesis, the faculty of the OGI School of Science & Engineering at Oregon Health & Science University, 2004.
- [13] M. Masoumnezhad, A. Moafi, A. Jamali, N. Narimanzadeh, Optimal design of mixed Kalman H-infinity filter using multi objective optimization method, *Modares Mechanical Engineering*, Vol. 14, pp. 128-132, 2014. (In Persian)
- [14] X. Wu, Y. Wang, Extended and Unscented Kalman filtering based feedforward neural networks for time series prediction, *Applied Mathematical Modelling*, Vol. 36, No. 3, pp. 1123-1131, 2012.