

یادداشت مهندسی

روش‌های برخط جهت شناسایی مدل هواپیما: بررسی مروری و مقایسه‌ای

امیر فرهاد احيائي^۲صبا محمد حسینی^۲فائزه حسینی^۱

گروه مهندسی برق دانشگاه بین المللی امام خمینی، قزوین، ایران

(تاریخ دریافت: ۱۳۹۸/۰۹/۱۹؛ تاریخ پذیرش: ۱۳۹۹/۱۱/۰۱)

چکیده:

در مقاله حاضر، یک بررسی مقایسه‌ای نسبتاً جامع از روش‌های شناسایی برخط بر روی مدل دینامیکی یک سیستم هواپیما ارائه شده است. برای این منظور ضمن معرفی انواع الگوریتم‌های موجود در این زمینه از الگوریتم‌های حداقل مربعات بازگشتی، حداقل مربعات تعمیم‌یافته بازگشتی، متغیرهای کمکی بازگشتی، ماتریس توسعه یافته، شبکه عصبی توابع پایه شعاعی و شبکه عصبی پرسپترون چند لایه با الگوریتم یادگیری پس انتشار برای شناسایی مدل فوق استفاده می‌شود. جهت انجام شبیه‌سازی‌ها و نیز آموزش شبکه‌های عصبی از مدل خطی شده و داده‌های هواپیمای بوئینگ ۷۴۷ که توسط کنترل کننده مد لغزشی بر روی مسیر مرجع دلخواه کنترل می‌شود، استفاده شده است. در نهایت نیز عملکرد روش‌های شناسایی مذکور ارزیابی و با یکدیگر مقایسه می‌شوند. بر اساس نتایج این مقاله، روش شبکه عصبی توابع پایه شعاعی به دلیل عدم استفاده از مدل خطی سیستم، تخمین دینامیک نوین، عدم نیاز به مدل سیستم و دقت بالاتر در عین سرعت مناسب، از برتری چشمگیری نسبت به سایر روش‌ها برخوردار است.

واژه‌های کلیدی: شناسایی سیستم، کنترل مد لغزشی، الگوریتم‌های بازگشتی، شبکه عصبی، توابع پایه شعاعی، پرسپترون چند لایه

Online Methods for the Identification of Aircraft Model: Review and Comparison

F. Hosseini^۲S. M. Hosseini^۲A. F. Ehyaei^۱

Electrical Engineering Department, Imam Khomeini International University, Qazvin, Iran

(Received: 10/12/2019; Accepted: 20/01/2020)

ABSTRACT

In this paper, a fairly comprehensive comparative study has been done on online identification methods for the dynamic model of an aircraft system. To this aim, first, the existing algorithms in this field are introduced. Then, some of these approaches including the recursive least square, the recursive extended least square, the recursive instrumental variable, the extended matrix, the radial basis function neural network, and the multilayer perceptron neural network are utilized to identify the aircraft model. To carry out the simulations, and train the neural networks, the linearized model and online data of the Boeing 747 aircraft controlled by a sliding mode controller on an arbitrary reference trajectory are employed. Finally, the efficiency of each of the above-mentioned methods is evaluated and compared to the other approaches. According to the obtained results of this research, the radial basis function neural network method has a significantly superior performance over the other algorithms due to dynamic noise estimation, independence from the system model, rejecting the linear model of the system, and higher accuracy while maintaining the appropriate speed.

Keywords: System Identification, Sliding Mode Control, Recursive Algorithms, Neural Network, Radial Basis Function, Multilayer Perceptron

^۱ دانشجوی کارشناسی ارشد: sf.hosseini@edu.ikiu.ac.ir^۲ دانشجوی کارشناسی ارشد: s.mhosseini@edu.ikiu.ac.ir^۳ استادیار (نویسنده پاسخگو): f.ehyaei@eng.ikiu.ac.ir

۱- مقدمه

استفاده شده است. در مراجع [۱۰ و ۱۱] از این روش جهت تخمین ضرایب آیرودینامیکی هواپیما استفاده شده است. مرجع [۱۲] از فیلتر کالمن توسعه یافته، تبدیل فوریه گسسته، روش خطای خروجی و حداقل مربعات بازگشتی جهت شناسایی شاخص‌های هواپیما بهره می‌برد و روش‌های مذکور را با یکدیگر مقایسه می‌نماید. همچنین مولفان در [۱۳]، دو روش مبتنی بر حداقل میانگین مربعات و حداقل مربعات بازگشتی جهت شناسایی شاخص‌های هواپیمای جنگنده مطرح نموده‌اند.

در [۱۴-۱۸] از روش شناسایی حداکثر احتمال وقوع بازگشتی^۴ بترتیب جهت شناسایی شاخص‌های هواپیما، سیستم تونل باد، هواپیمای بدون سرنشین و وسیله نقلیه ماوراء صوت استفاده شده است. [۲۷-۱۹] از مدل‌های مختلفی همچون همراشتاین و وینر جهت شناسایی سیستم با استفاده از روش متغیرهای کمکی بازگشتی^۵ بهره گرفته‌اند. همچنین در مراجع [۲۸ و ۲۹] از روش حداقل مربعات توسعه یافته بازگشتی^۶ به ترتیب جهت شناسایی شاخص‌های سیستم غیرخطی تصادفی و سیستم غیر خطی وینر در حضور نویز میانگین متحرک استفاده شده است.

در مراجع [۳۰-۳۲] از شبکه عصبی پیشرو و در [۳۳-۳۵] به ترتیب از شبکه عصبی توابع پایه شعاعی^۷، شبکه عصبی بازگشتی و شبکه عصبی پرسپترون چندلایه^۸ جهت شناسایی مدل هواپیما استفاده شده است. همچنین در [۳۶] از شبکه‌های عصبی توابع پایه شعاعی و پرسپترون چندلایه و در [۳۷ و ۳۸] به ترتیب از شبکه‌های عصبی بازگشتی شامل: شبکه عصبی پرسپترون چندلایه بازگشتی و شبکه عصبی حافظه‌دار برای شناسایی سیستم هلیکوپتر بهره گرفته شده است.

در این مقاله به شناسایی سیستم هواپیمای بوئینگ ۷۴۷ با روش‌های شناسایی برخط از جمله: حداقل مربعات بازگشتی، حداقل مربعات توسعه یافته بازگشتی، متغیرهای کمکی بازگشتی، ماتریس توسعه یافته^۹، شبکه عصبی توابع پایه شعاعی و شبکه عصبی پرسپترون چند لایه پرداخته می‌شود. جهت انجام شبیه‌سازی‌ها و نیز آموزش شبکه‌های

یکی از چالش‌های مهم در پیاده‌سازی وسایل نقلیه پرنده همچون هواپیما، هلی‌کوپتر، کوادروتور و مانند آن شناسایی مدل سیستم در حین عملکرد آن می‌باشد که تاکنون توجه محققان بسیاری را به خود جلب نموده و برای این منظور راهکارهای متعددی در مراجع ارائه گردیده است. بر این اساس انجام یک بررسی مقایسه‌ای در این حوزه می‌تواند تاثیر به‌سزایی در ارائه یک روش سریع و دقیق داشته باشد.

به‌طور کلی روش‌های شناسایی سیستم در مراجع به دو دسته روش‌های مبتنی بر مدل و روش‌های مبتنی بر داده قابل تقسیم هستند. روش‌های مبتنی بر مدل خود به دو دسته روش‌های خاموش^۱ و روش‌های برخط^۲ تقسیم می‌شوند. روش‌های برخط به دلیل انجام عملیات شناسایی در حین عملکرد سیستم توانایی دنبال کردن تغییرات سیستم را دارا بوده و از این لحاظ برتری محسوس نسبت به روش‌های خاموش دارند. یکی از روش‌های مطرح در این زمینه روش‌های بازگشتی هستند. در این روش‌ها با اضافه شدن نمونه‌ها به صورت برخط در هر بار تکرار الگوریتم تخمین بهتری حاصل می‌شود.

در روش‌های مبتنی بر داده بر خلاف روش‌های مبتنی بر مدل، جهت شناسایی سیستم نیاز به مدل ریاضی سیستم نمی‌باشد و فقط با داشتن مجموعه‌ای از داده‌های ورودی و خروجی، سیستم مورد نظر قابل شناسایی است. بر این اساس، روش‌های مبتنی بر داده که معمول‌ترین آن‌ها روش‌های شبکه عصبی هستند، به دلیل عدم وابستگی به مدل از دقت بالاتری برخوردارند و قابلیت بکارگیری در کاربردهای شناسایی برخط برای طیف وسیع‌تری از سیستم‌ها را دارا هستند.

در [۱] از دو روش حداقل مربعات بازگشتی^۳ و لیاپانوف جهت شناسایی شاخص‌های هواپیما استفاده شده است و دو روش مذکور با یکدیگر مقایسه شده‌اند. در مقالات متعدد دیگری از روش حداقل مربعات بازگشتی جهت شناسایی سیستم‌های مختلف همچون مدل خطی شده هواپیمای ۶ درجه آزادی [۲]، سیستم هواپیمای بدون سرنشین [۷-۳]، سیستم هلیکوپتر مینیاتوری [۸] و سیستم دو روتوره [۹]

^۴ Recursive Maximum Likelihood (RML)

^۵ Recursive Instrumental Variable (RIV)

^۶ Recursive Extended Least Square (RELS)

^۷ Radial Basis Function (RBF)

^۸ Multilayer Perceptron (MLP)

^۹ Extended Matrix Method (EMM)

^۱ Offline Methods

^۲ Online Methods

^۳ Recursive Least Square (RLS)

مدل فضای حالت این سیستم نیز در (۴ و ۵) معرفی شده است [۳۹]:

$$\dot{x} = Ax(t) + Bu(t) \quad (۴)$$

$$y(t) = Cx(t) \quad (۵)$$

در این روابط، $x(t) = (\beta, y_r, P, \phi)^T$ بردار حالت سیستم است که شامل: زاویه مجانبی، نرخ یاو، نرخ رول و زاویه رول و $u(t) = (u_1, u_2, u_3)^T$ بردار ورودی می‌باشند. همچنین ماتریس‌های A, B, C ذکر شده در (۴ و ۵) از روابط (۶-۸) محاسبه می‌شوند [۳۹]:

$$A = \begin{bmatrix} -0.0558 & -0.9968 & 0.0802 & 0.0415 \\ 0.598 & -0.115 & -0.0318 & 0 \\ -3.05 & 0.388 & -0.465 & 0 \\ 0 & 0.0805 & 1 & 0 \end{bmatrix} \quad (۶)$$

$$B = \begin{bmatrix} 0.00729 & 0.01 & 0.005 \\ -0.475 & -0.5 & -0.3 \\ 0.153 & 0.2 & 0.1 \\ 0 & 0 & 0 \end{bmatrix} \quad (۷)$$

$$C = [0 \quad 1 \quad 0 \quad 0] \quad (۸)$$

در نهایت معادله دینامیک فوق را می‌توان به فرم معادله رگرسیون خطی $y_t = (u_t^T)\theta + e_t$ نوشت که در آن y_t خروجی سیستم در لحظه t ، u_t برداری متشکل از اطلاعات معلوم سیستم در زمان t و زمان‌های ماقبل t ، θ بردار شاخص‌های مجهول مدل سیستم و e_t سیگنال خطا در لحظه t می‌باشد.

۳- کنترل کننده مد لغزشی

کنترل کننده مد لغزشی به علت دارا بودن مزایایی همچون: سادگی در طراحی، عدم حساسیت به تغییر مولفه‌ها و اغتشاش جزو پرکاربردترین کنترل کننده‌های غیرخطی می‌باشد. طراحی این کنترل کننده شامل دو مرحله اصلی: طراحی سطح لغزش و طراحی قانون کنترل مناسب است. در حالت کلی و برای سیستم مرتبه n سطح لغزش مناسب را می‌توان طبق (۹) انتخاب نمود:

$$S = \left(\frac{d}{dt} + \lambda\right)^{(n-1)} E \quad (۹)$$

عصبی از مدل خطی شده و داده‌های هواپیمای بوئینگ ۷۴۷ که توسط کنترل کننده مد لغزشی بر روی مسیر مرجع دلخواه کنترل می‌شود، استفاده شده است. در پایان نیز نتایج حاصل از شش روش شناسایی معرفی شده ارزیابی و با یکدیگر مقایسه می‌شوند.

بر این اساس در ادامه، در فصل ۱ معادلات هواپیمای بوئینگ ۷۴۷ شرح داده می‌شود. در بخش ۲ نتایج اعمال کنترل کننده مد لغزشی بر روی سیستم هواپیمای بوئینگ ۷۴۷ نمایش داده می‌شود. در فصل ۳ الگوریتم‌های شناسایی برخط معرفی می‌شوند و در فصل ۴ انواع روش‌های شناسایی مذکور بر روی مدل هواپیما شبیه‌سازی و تحلیل می‌شود. نهایتاً در فصل ۵ جمع‌بندی مقاله ارائه می‌شود.

۲- مدل هواپیمای بوئینگ ۷۴۷

هواپیمای بوئینگ ۷۴۷ معروف به جمبوجت، هواپیمای جت بزرگ مسافربری می‌باشد. این هواپیمای چهار موتوره قابلیت پرواز تا سرعت ۹۶۷ km/h را داراست. وزن هواپیمای خالی عملیاتی شده ۱۶۲۳۸۶ kg و توانایی تحمل حداکثر ۳۴۰۱۹۵ kg را در هنگام پرواز داراست. در حالت کلی می‌توان تابع تبدیل سیستم خطی شده این هواپیما را به صورت رابطه (۱) نمایش داد [۳۹]:

$$y(t) = \sum_{j=1}^m G_j(s) u_j(t) \quad (۱)$$

که m تعداد ورودی سیستم می‌باشد و همچنین $G_j(s)$ نیز مطابق (۲) قابل محاسبه می‌باشد:

$$G_j(s) = \frac{b_j(s)}{a(s)} = \frac{(b_{jpi}s^{pi} + \dots + b_{j0})}{(s^n + a_{(n-1)}s^{(n-1)} + \dots + a_0)} \quad (۲)$$

با توجه به حالت کلی تابع تبدیل سیستم که در روابط (۱ و ۲) معرفی شدند، تابع تبدیل مدل خطی شده حرکت جانبی هواپیمای بوئینگ که یک سیستم سه ورودی- تک خروجی است مطابق رابطه (۳) به دست می‌آید [۳۹]:

$$y(t) = \frac{(-0.475s^3 - 0.2479s^2 - 0.1187s - 0.05633)}{(s^4 + 0.6358s^3 + 0.9389s^2 + 0.5116s + 0.003674)} u_1(t) + \frac{(-0.5s^3 - 0.2608s^2 - 0.1223s - 0.05832)}{(s^4 + 0.6358s^3 + 0.9389s^2 + 0.5116s + 0.003674)} u_2(t) + \frac{(-0.3s^3 - 0.1564s^2 - 0.7467s - 0.03549)}{(s^4 + 0.6358s^3 + 0.9389s^2 + 0.5116s + 0.003674)} u_3(t) \quad (۳)$$


همانطور که از شکل ۱ مشخص است، خروجی سیستم هواپیمای بوئینگ ۷۴۷ با اعمال کنترل کننده مدلغزشی به خوبی توانسته است که مسیر مرجع را دنبال یابی کند.

۴- الگوریتم‌های شناسایی برخط

در ادامه به بررسی الگوریتم‌های شناسایی برخط، پرداخته می‌شود.

۴-۱- شبکه عصبی توابع پایه شعاعی

شبکه‌های عصبی توابع پایه شعاعی در کاربردهای متفاوتی همانند: تقریب توابع، درون‌یابی و کلاس‌بندی مورد استفاده قرار می‌گیرند. ساختار این نوع از شبکه‌های عصبی در شکل ۲ نمایش داده شده است [۴۰].



شکل (۲): ساختار شبکه‌های عصبی توابع پایه شعاعی [۴۰]

در شکل (۲)، مربع‌ها بردار ورودی، دایره‌های لایه میانی نورون‌های لایه میانی، دایره‌های لایه آخر نیز نورون‌های لایه خروجی می‌باشند. تابع فعال‌ساز نورون‌های لایه میانی، تابعی از تفاضل بردار ورودی و بردار مرکز دسته می‌باشد.

جهت تعیین مرکز دسته روش‌های گوناگونی از جمله: الگوریتم میانگین کا^۱ وجود دارد. عملکرد شبکه‌های عصبی توابع پایه شعاعی در حقیقت نوعی نگاشت غیرخطی از فضای ورودی به فضایی با ابعاد بزرگتر از فضای ورودی می‌باشد. عملیات یادگیری در شبکه‌های عصبی به طور کلی به دو دسته: یادگیری با معلم و یادگیری بدون معلم قابل تقسیم می‌باشد. در روش یادگیری با معلم که به یادگیری نظارت شده نیز معروف می‌باشد مقدار هدف مشخص است و شبکه عصبی می‌بایست به خروجی برسد که بیشترین شباهت را با مقدار هدف داشته باشد. در روش یادگیری بدون نظارت

که $\lambda > 0$ و E میزان خطای بین سیگنال خروجی واقعی سیستم و سیگنال مرجع دلخواه می‌باشد. هنگامی که خروجی واقعی سیستم و خروجی دلخواه یکسان نباشند، نیاز است که سیستم به سطح لغزش طراحی شده همگرا شود. با انتخاب تابع لیاپانوف و اثبات منفی بودن مشتق تابع لیاپانوف طبق (۱۰) می‌توان علاوه بر اثبات پایداری سیستم به شرطی دست یافت که به شرط لغزش موسوم است:

$$V(x) = \frac{1}{2}S^2 \rightarrow \dot{V}(x) = S\dot{S} = \frac{1}{2} \frac{d}{dt} S^2 \leq -\eta |S| \quad (10)$$

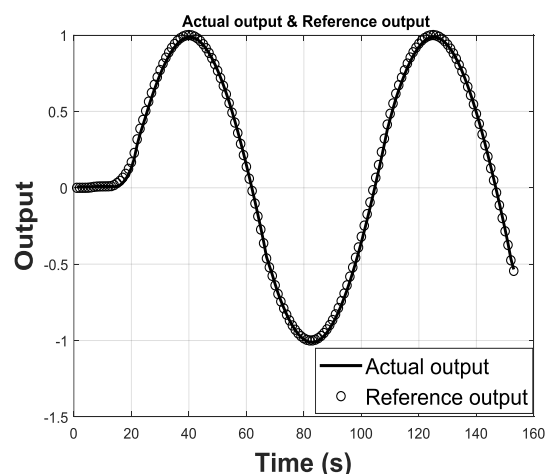
که $\eta > 0$. پس از انتخاب سطح لغزش باید قانون کنترل را به گونه‌ای انتخاب نماییم که متغیر کنترلی به سمت مقدار مرجع دلخواه همگرا شود. در حالت کلی می‌توان مقدار ورودی کنترلی را از رابطه زیر به دست آورد:

$$u = u - k \operatorname{sgn}(s) \quad (11)$$

که u از کنترل کننده خطی ساز باز خورد به دست می‌آید و k به گونه‌ای انتخاب می‌شود که شرط لغزش تعریف شده در رابطه (۱۰) برآورده شود. تابع علامت نیز طبق (۱۲) تعریف می‌شود:

$$\operatorname{sgn}(s) = \begin{cases} +1 \rightarrow s > 0 \\ 0 \rightarrow s = 0 \\ -1 \rightarrow s < 0 \end{cases} \quad (12)$$

در این مقاله مسیر مرجع دلخواه به صورت $y_{ref} = \sin(t)$ انتخاب شده است. شکل ۱ نتیجه اعمال کنترل کننده مدلغزشی را بر روی سیستم هواپیمای بوئینگ ۷۴۷ نمایش می‌دهد.



شکل (۱): دنبال‌یابی مسیر سینوسی توسط خروجی سیستم

^۱ k-means

این روش به علت سرعت بالای محاسبات در کنترل تطبیقی بسیار پرکاربرد می‌باشد. از معایب این روش می‌توان به: عدم تخمین دینامیک نویز و بایاس‌دار بودن تخمین در صورت سفید نبودن نویز اشاره نمود. الگوریتم این روش شناسایی مطابق مراحل زیر می‌باشد [۴۱]:

۱. در لحظه t ورودی و خروجی را می‌خوانیم.

۲. بردار u_t^T که شامل اطلاعات معلوم سیستم در زمان حال و زمان ماقبل می‌باشد، مطابق (۱۴) محاسبه می‌شود:

$$u_t^T = [-y_{(t-1)} \dots y_{(t-n)} x_t \dots x_{(t-m)}] \quad (14)$$

۳. بردار k_t به صورت زیر به دست می‌آید:

$$k_t = \frac{(p_{(t-1)} \cdot u_t)}{(1 + u_t^T \cdot p_{(t-1)} \cdot u_t)} \quad (15)$$

۴. بردار θ_t نیز مطابق رابطه زیر تعیین می‌شود:

$$\theta_t = \theta_{(t-1)} + k_t (y_t - u_t^T \theta_{(t-1)}) \quad (16)$$

۵. ماتریس p_t را مطابق رابطه (۱۷) محاسبه می‌کنیم:

$$p_t = (I - k_t u_t^T) p_{(t-1)} \quad (17)$$

۶. در نهایت نیز تست توقف (۱۸) را بررسی می‌کنیم در صورت درست نبودن ناپرابری زیر به مرحله (۱) می‌رویم.

$$\|\theta_t - \theta_{t-1}\| < \varepsilon \quad (18)$$

۴-۴- حدافل مربعات توسعه یافته بازگشتی

یکی از روش‌های شناسایی بازگشتی، روش حدافل مربعات توسعه یافته بازگشتی می‌باشد. این روش نسبت به حدافل مربعات بازگشتی دارای مزایای: تخمین بدون بایاس شاخص‌های سیستم و تخمین دینامیک نویز می‌باشد اما سرعت تخمین این روش نسبت به روش حدافل مربعات بازگشتی کمتر می‌باشد. الگوریتم این روش شناسایی مطابق مراحل زیر است [۴۱]:

۱. در لحظه t ورودی و خروجی را می‌خوانیم.


۲. بردار u_t^T را در لحظه t مطابق (۱۹) محاسبه می‌شود:

$$u_t^T = [-y_{(t-1)} \dots y_{(t-n)} x_t \dots x_{(t-m)} v_{t-1} \dots v_{t-l}] \quad (19)$$

مقدار هدف مشخص نمی‌باشد که خود به دو روش یادگیری تقویتی و یادگیری غیر نظارت شده قابل تقسیم می‌باشد. در این مقاله از الگوریتم پس انتشار^۱ که یکی از الگوریتم‌های روش یادگیری نظارت شده می‌باشد، استفاده شده است.

۴-۲- شبکه عصبی پرسپترون چندلایه

شبکه‌های عصبی پرسپترون چندلایه به علت ساختار ساده یکی از پرکاربردترین انواع شبکه عصبی می‌باشند. این نوع از شبکه‌ها دارای یک لایه ورودی، حدافل یک لایه پنهان و یک لایه خروجی می‌باشند. شکل ۳ ساختار این نوع شبکه‌ها را نمایش می‌دهد.



شکل (۳): ساختار شبکه عصبی پرسپترون چندلایه [۳۱]

در شکل (۳) دایره‌های سمت چپ ورودی‌های شبکه، دایره‌های وسط نورون‌های لایه میانی و دایره‌های سمت راست خروجی شبکه عصبی می‌باشند که خروجی هر لایه این نوع از شبکه‌های عصبی به صورت زیر محاسبه می‌شود:

$$y_j = f\left(\sum_{i=1}^N W_{ji} x_i + b_j\right) \quad (13)$$

که f تابع فعالساز^۲ هر نورون، W_{ji} وزن بین ورودی i ام و نورون j ام و b_j مقدار آستانه نورون j ام می‌باشد. در این مقاله جهت آموزش شبکه عصبی پرسپترون چندلایه از الگوریتم پس انتشار استفاده شده است.

۴-۳- الگوریتم حدافل مربعات بازگشتی

در روش شناسایی حدافل مربعات بازگشتی، تخمین شاخص‌های سیستم بر مبنای مجموع مربعات خطا بین مقدار واقعی و مقدار تخمین زده شده مولفه می‌باشد [۱۳].

¹ Back Propagation

² Activation function

۶. در نهایت نیز تست توقف (۲۹) را بررسی می‌کنیم در صورت درست نبودن نابرابری زیر به مرحله (۱) می‌رویم.

$$\|\theta_t - \theta_{t-1}\| < \varepsilon \quad (29)$$

۴-۶- ماتریس توسعه یافته

یکی دیگر از روش‌های شناسایی بازگشتی، روش ماتریس توسعه یافته می‌باشد. الگوریتم این روش مطابق مراحل زیر است [۴۱]:

در لحظه t ورودی و خروجی را می‌خوانیم.

۱. بردار u_t^T در لحظه t مطابق (۳۰) محاسبه می‌شود:

$$u_t^T = [-y_{(t-1)} \dots - y_{(t-n)} X_{t-1} \dots X_{(t-m)} \hat{e}_{(t-1)}] \quad (30)$$

$$\dots \hat{e}_{(t-nd)} \dots V_{(t-1)} \dots V_{(t-1)}]$$

۲. ماتریس P_t نیز به صورت زیر به دست می‌آید:

$$P_t = P_{t-1} - \frac{(P_{(t-1)} \cdot u_t \cdot u_t^T P_{(t-1)})}{(1 + u_t^T \cdot P_{(t-1)} \cdot u_t)} \quad (31)$$

۳. θ_t بردار مطابق (۳۲) قابل محاسبه می‌باشد:

$$\theta_t = \theta_{(t-1)} + k_t (y_t - u_t^T \theta_{(t-1)}) \quad (32)$$

۴. v_t و \hat{e}_t از طبق روابط زیر تخمین زده می‌شود:

$$v_t = y_t - u_t^T \theta_t \quad (33)$$

$$\hat{e}_t = y_t - u_{1t}^T \theta_{1t} \quad (34)$$

۵. در نهایت نیز تست توقف (۳۵) را بررسی می‌کنیم در صورت درست نبودن نابرابری زیر به مرحله (۱) می‌رویم.

$$\|\theta_t - \theta_{t-1}\| < \varepsilon \quad (35)$$

۵- شبیه‌سازی

در این بخش شش روش فوق در شناسایی هواپیمای بوئینگ ۷۴۷ مقایسه می‌شوند. شکل ۴ نتایج حاصل را نمایش می‌دهد.

۳. ماتریس P_t نیز طبق (۲۰) محاسبه می‌شود:

$$P_t = P_{t-1} - \frac{(P_{(t-1)} \cdot u_t \cdot u_t^T P_{(t-1)})}{(1 + u_t^T \cdot P_{(t-1)} \cdot u_t)} \quad (20)$$

۴. بردار θ_t مطابق (۲۱) قابل محاسبه می‌باشد:

$$\theta_t = \theta_{(t-1)} + p_t u_t (y_t - u_t^T \theta_{(t-1)}) \quad (21)$$

۵. v_t طبق (۲۲) تخمین زده می‌شود:

$$v_t = y_t - u_t^T \theta_t \quad (22)$$

۶. در نهایت نیز تست توقف (۲۳) را بررسی می‌کنیم در صورت درست نبودن نابرابری زیر به مرحله (۱) می‌رویم.

$$\|\theta_t - \theta_{t-1}\| < \varepsilon \quad (23)$$

۴-۵- روش متغیرهای کمکی بازگشتی

روش متغیرهای کمکی بازگشتی نسبت به روش شناسایی حداقل مربعات بازگشتی دارای مزایای: تخمین بدون بایاس شاخص‌های سیستم و تخمین دینامیک نویز می‌باشد؛ اما از لحاظ سرعت از روش حداقل مربعات بازگشتی کندتر و از روش حداقل مربعات توسعه یافته بازگشتی سریعتر می‌باشد. مراحل زیر الگوریتم شناسایی بر اساس این روش را نمایش می‌دهد [۴۱]:

۱. در لحظه t ورودی و خروجی را می‌خوانیم.

۲. بردار u_t^T و Z_t^T را در لحظه t مطابق روابط (۲۴) و (۲۵) محاسبه می‌شوند:

$$u_t^T = [-y_{(t-1)} \dots - y_{(t-n)} X_{t-1} \dots X_{(t-m)}] \quad (24)$$

$$Z_t^T = [-y_{(t-1)} \dots - y_{(t-n)} X_{t-1} \dots X_{(t-m)}] \quad (25)$$

۳. ماتریس P_t نیز به صورت زیر محاسبه می‌شود:

$$P_t = P_{t-1} - \frac{(P_{(t-1)} \cdot Z_t \cdot u_t^T P_{(t-1)})}{(1 + u_t^T \cdot P_{(t-1)} \cdot Z_t)} \quad (26)$$

۴. بردار θ_t مطابق (۲۷) قابل محاسبه است:

$$\theta_t = \theta_{(t-1)} + p_t Z_t (y_t - u_t^T \theta_{(t-1)}) \quad (27)$$

۵. y_t طبق رابطه (۲۸) تخمین زده می‌شود:

$$y_t = u_t^T \theta_t \quad (28)$$

جدول (۱): سرعت اجرای الگوریتم‌های شناسایی

روش شناسایی	سرعت اجرای الگوریتم
حداقل مربعات بازگشتی	۰/۰۶۴۶۳۱ s
حداقل مربعات توسعه یافته بازگشتی	۰/۰۵۸۱۸۹ s
ماتریس توسعه یافته	۱/۰۷۴۱۸۱ s
متغیرهای کمکی بازگشتی	۰/۰۴۷۴۷۳ s
شبکه عصبی توابع پایه شعاعی	۰/۱۸۴۸۴۶ s
شبکه عصبی پرسپترون چند لایه	۲/۵۸۳۳۸۶ s


همانطور که در جدول ۱ مشاهده می‌شود، روش متغیر کمکی بازگشتی در شناسایی سیستم هواپیمای بوئینگ سرعت بیشتری نسبت به سایر روش‌های شناسایی برخط را داراست. پس از آن: روش حداقل مربعات توسعه یافته بازگشتی، روش حداقل مربعات بازگشتی، شبکه عصبی توابع پایه شعاعی، روش ماتریس توسعه یافته و در نهایت روش شبکه عصبی پرسپترون چندلایه به ترتیب دارای بیشترین سرعت اجرای الگوریتم هستند.

جدول ۲ نیز روش‌های شناسایی بازگشتی را از لحاظ توانایی در تخمین دینامیک نویز با توجه به الگوریتم‌های ارائه شده در این مقاله نمایش می‌دهد:

جدول (۲): توانایی تخمین دینامیک نویز

الگوریتم‌های شناسایی


روش شناسایی	توانایی تخمین دینامیک نویز
حداقل مربعات بازگشتی	ندارد
حداقل مربعات توسعه یافته بازگشتی	دارد
ماتریس توسعه یافته	دارد
متغیرهای کمکی بازگشتی	ندارد



شکل (۴): نتیجه شناسایی سیستم هواپیمای بوئینگ ۷۴۷ به کمک روش‌های شناسایی برخط

همانطور که از شکل ۴ نمایان است، تقریباً شش روش شناسایی مذکور به خوبی توانسته‌اند که سیستم را شناسایی نمایند. یکی از مزایای استفاده از شبکه‌های عصبی عدم نیاز به داشتن مدل ریاضی سیستم حین شناسایی سیستم هواپیمای بوئینگ می‌باشد.

در شکل ۵ نمودار میله‌ای مجموع مربعات خطا برای هر شش روش استفاده شده جهت شناسایی سیستم نمایش داده شده است. بدیهی است که هرچه میزان این خطا کمتر باشد، روش شناسایی دارای صحت بیشتری می‌باشد و مولفه تخمین زده شده به مقدار واقعی خود نزدیکتر می‌باشد.



شکل (۵): نمودار مجموع مربعات خطا

همانطور که از شکل ۵ مشخص است، روش‌های شناسایی شبکه عصبی پرسپترون چندلایه، حداقل مربعات توسعه یافته بازگشتی، متغیرهای کمکی بازگشتی، ماتریس توسعه یافته، حداقل مربعات بازگشتی و شبکه عصبی توابع پایه شعاعی به ترتیب دارای بیشترین تا کمترین خطا در تخمین شاخص‌های سیستم می‌باشند. مدت زمان اجرای الگوریتم شش روش مذکور در جدول ۱ برای ۱۵۳ دوره با یکدیگر مقایسه شده‌اند.

7. Hoffer, N.V., et al. Small low-cost unmanned aerial vehicle System identification by Error Filtering Online Learning (EFOL) enhanced least squares method. in International Conference on Unmanned Aircraft Systems (ICUAS). 2015. IEEE.
8. Raptis, I.A., K.P. Valavanis, and W.A. Moreno, System identification and discrete nonlinear control of miniature helicopters using backstepping. *Journal of Intelligent and Robotic Systems*, Vol. 55, No. 2-3, pp. 223-243, 2009.
9. Toha, S. and M. Tokhi, Parametric modelling application to a twin rotor system using recursive least squares, genetic, and swarm optimization techniques. *Proceedings of the Institution of Mechanical Engineers, Part G: Journal of Aerospace Engineering*, Vol. 224, No. 9, pp. 961-977. 2010
10. Kim, W.-J., J. LEE, and D. LEE. Application of recursive partially unknown system identification to aerodynamic coefficients estimation. in *Astrodynamics Conference*, 1992.
11. Grauer, J.A. Parameter uncertainty for aircraft aerodynamic modeling using recursive least squares. in *AIAA atmospheric flight mechanics conference*. 2016.
12. Basappa, K. and R. Jategaonkar. Evaluation of recursive methods for aircraft parameter estimation. in *AIAA Atmospheric Flight Mechanics Conference and Exhibit*. 2004.
13. Qadri, M.T., et al., Comparative analysis of LMS (Least Mean Square) and RLS (Recursive Least Square) for estimation of fighter plane's mathematical model. *Journal of Information and Communication Technology*, Vol. 10, No. 1, pp. 35-46, 2016.
14. Andrzejczak, V., *Methods applied to aircraft identification*. 2011.
15. Singh, S. and A. Ghosh. Parameter estimation from flight data of a missile using maximum likelihood and neural network method. in *AIAA Atmospheric Flight Mechanics Conference and Exhibit*, 2006.
16. Saderla, S., Y. Kim, and A. Ghosh, Online system identification of mini cropped delta UAVs using flight test methods. *Aerospace Science and Technology*, Vol. 80, pp. 337-353, 2018.
17. Ma, L. and X. Liu, Recursive maximum likelihood method for the identification of Hammerstein ARMAX system. *Applied Mathematical Modelling*, Vol. 40, No. 13-14, pp. 6523-6535, 2016

همانطور که از جدول ۲ مشخص است، تنها دو روش شناسایی بازگشتی حداقل مربعات و متغیرهای کمکی توانایی تخمین دینامیک نويز را ندارند.

۶- نتیجه گیری

در این مقاله سعی بر آن بود که مقایسه‌ای بین روش‌های برخط شامل الگوریتم‌های شناسایی بازگشتی و شبکه عصبی جهت شناسایی مدل خطی یک هواپیمای بوئینگ ۷۴۷ صورت پذیرد. برای این منظور ۶ روش مختلف مورد ارزیابی و مقایسه قرار گرفتند. بر اساس نتایج شبیه‌سازی‌ها روش متغیرهای کمکی بازگشتی سریع‌ترین پاسخ و روش شبکه عصبی توابع پایه شعاعی دقیق‌ترین پاسخ را در میان کلیه روش‌های تحت بررسی دارا هستند. بر اساس نتایج این مقاله، روش شبکه عصبی توابع پایه شعاعی به دلیل عدم استفاده از مدل خطی سیستم، تخمین دینامیک نويز، عدم نیاز به مدل سیستم و دقت بالاتر در عین سرعت مناسب، از برتری چشمگیری نسبت به سایر روش‌ها برخوردار است.

۷- مراجع

1. Nguyen, N.T. and K. Krishnakumar, Hybrid intelligent flight control with adaptive learning parameter estimation. *Journal of Aerospace Computing, Information, and Communication*, Vol. 6, No.3, pp. 171-186, 2009.
2. DeBusk, W., E. Johnson, and G. Chowdhary. Real-time system identification of a small multi-engine aircraft. in *AIAA Atmospheric Flight Mechanics Conference*, 2009.
3. Birnbaum, Z., et al., Unmanned aerial vehicle security using recursive parameter estimation. *Journal of Intelligent & Robotic Systems*, Vol. 84, No. 1-4 pp. 107-120, 2016.
4. Hatamleh, K., O. Ma, and R. Paz. In-flight UAV model parameter identification: A simulation study. in *AIAA Atmospheric flight mechanics conference*. 2009.
5. Lee, R. and L. Shen, System identification of cessna 182 model uav. preprinted, 2005.
6. Zhe, L., Z. Yue-rong, and W. Gui-dong. Online parameter identification study on a small fixed-wing UAV. in *IEEE Chinese Guidance, Navigation and Control Conference (CGNCC)*, 2016. IEEE.

30. Raisinghani, S., A. Ghosh, and P. Kalra, Two new techniques for aircraft parameter estimation using neural networks. *The aeronautical journal*, Vol. 102, No. 1011, pp. 25-30, 1998.
31. Ghazi, G., et al. Cessna citation X stall characteristics identification from flight data using neural networks. in *AIAA Atmospheric Flight Mechanics Conference*. 2017.
32. Ghosh, A. and S. Raisinghani, Frequency-domain estimation of parameters from flight data using neural networks. *Journal of Guidance, Control, and Dynamics*, Vol. 24, No.3, pp. 525-530, 2001.
33. Kumar, R., et al., Rotorcraft parameter identification from real time flight data. *Journal of Aircraft*, Vol. 45, No.1, pp. 333-341, 2008.
34. Raol, J. and R. Jategaonkar. Aircraft parameter estimation using recurrent neural networks-A critical appraisal. in *20th Atmospheric Flight Mechanics Conference*. 1995.
35. Wallach, R., et al. Aerodynamic coefficient prediction of transport aircraft using neural network. in *44th AIAA Aerospace Sciences Meeting and Exhibit*. 2006.
36. Muñoz, R.S.M., C. Rossi, and A.B. Cruz, Modelling and Identification of Flight Dynamics in Mini-Helicopters Using Neural Networks, in *Aerial Vehicles*. 2009, IntechOpen.
37. Kumar, M.V., et al., Identification of helicopter dynamics using recurrent neural networks and flight data. *Journal of the American Helicopter Society*, Vol. 51, No.2, pp. 164-174, 2006.
38. Suresh, S., et al. Neural networks based identification of helicopter dynamics using flight data. in *Proceedings of the 9th International Conference on Neural Information Processing*. 2002. IEEE.
39. Chen, W. and M. Saif, Adaptive actuator fault detection, isolation and accommodation in uncertain systems. *International Journal of Control*, Vol. 80, No.1, pp. 45-63, 2007.
40. Faris, H., I. Aljarah, and S. Mirjalili, Evolving radial basis function networks using moth-flame optimizer, in *Handbook of Neural Computation*, Elsevier. pp. 537-550, 2017.
41. karari, m., System identification. 1394, Tehran: Amir kabir university. (In persian).
18. Hu, C. and Q. Liu. Online identification for hypersonic vehicle using recursive maximum likelihood method based on interior-point algorithm. in *25th Chinese Control and Decision Conference (CCDC)*, 2013. IEEE.
19. Söderström, T. and P. Stoica, Instrumental variable methods for system identification. *Circuits, Systems and Signal Processing*, Vol. 21, No.1, pp. 1-9, 2002.
20. Cedervall, M. and P. Stoica, System identification from noisy measurements by using instrumental variables and subspace fitting. *Circuits, Systems and Signal Processing*, Vol. 15, No. 2, pp. 275-290, 1996.
21. Chen, X. and H.-T. Fang, Recursive subspace method for wiener systems using instrumental variable techniques. *IFAC Proceedings*, Vol. 45, No. 16, pp. 1508-1513, 2012.
22. Friedlander, B., The overdetermined recursive instrumental variable method. *IEEE Transactions on Automatic Control*, Vol. 29 No.4, pp. 353-356, 1984.
23. HUFFEL, S.V. and J. Vandewalle, Comparison of total least squares and instrumental variable methods for parameter estimation of transfer function models. *International journal of control*, Vol. 50, No.4, pp. 1039-1056, 1989.
24. Ma, L. and X. Liu, A nonlinear recursive instrumental variables identification method of Hammerstein ARMAX system. *Nonlinear Dynamics*, Vol. 79, No.2, pp. 1601-1613, 2015.
25. Strobach, P., Bi-iteration recursive instrumental variable subspace tracking and adaptive filtering. *IEEE transactions on signal processing*, Vol. 46, No.10 pp. 2708-2725, 1998.
26. Young, P.C., An instrumental variable method for real-time identification of a noisy process. *Automatica*, Vol. 6, No.2, pp. 271-287, 1970.
27. Young, P.C., Refined instrumental variable estimation: maximum likelihood optimization of a unified Box-Jenkins model. *Automatica*, Vol. 52, pp. 35-46. 2015
28. Chen, H. Extended recursive least squares algorithm for nonlinear stochastic systems. in *Proceedings of the American Control Conference*. 2004. IEEE.
29. Hu, Y., et al., Recursive extended least squares parameter estimation for Wiener nonlinear systems with moving average noises. *Circuits, Systems, and Signal Processing*, Vol. 33, No.2, pp. 655-664. 2014