

# شناسایی دینامیک فضای حالت یک پرندهی بال ثابت به وسیلهی شبکهی عصبی خطی با استفاده از داده‌های آزمون پرواز

افشین بنازاده\* (دانشیار)

هادی نوبهارى (دانشیار)

یوسف صیفوری پور (دانشجوی دکتری)

دانشکدهی مهندسی هوافضا، دانشگاه صنعتی شریف

مهندسی مکانیک شریف، (بهار ۱۳۹۸)  
دورهی ۳-۳، شمارهی ۱، ص. ۲۲-۱۳

در این پژوهش، دینامیک یک پهپاد بال ثابت دارای کانارد به کمک شبکهی عصبی خطی و با استفاده از داده‌های آزمون پروازی شناسایی شده است. با توجه به کوپلینگ<sup>۱</sup> دینامیک طولی و عرضی پرنده، شناسایی به صورت چندورودی - چندخروجی (بدون تفکیک دینامیک طولی و عرضی) و در دو حالت انجام شده است. در حالت اول، هدف شناسایی دینامیک پرنده به گونهی است که بتوان از آن در طراحی کنترل کنندهی چندورودی - چندخروجی استفاده کرد و در حالت دوم، هدف شناسایی دینامیک پرنده به گونهی است که بتوان از آن در شبیه سازی نرم افزاری پرنده بهره برد. برای شناسایی دینامیک، از روش چندورودی - چندخروجی<sup>۲</sup> (SSEST) نیز استفاده شده است. مقایسهی نتایج به دست آمده حاکی از آن است که کیفیت شناسایی دینامیک پرنده با استفاده از شبکهی عصبی خطی مناسب، و با سایر روش های شناسایی چندورودی - چندخروجی قابل مقایسه است. این روش شناسایی، ساده و حجم محاسبات آن کم است. بنابراین، این روش برای شناسایی برخط (Online) دینامیک پرنده یا تشخیص عیب نیز قابل استفاده است.

واژگان کلیدی: شبکهی عصبی خطی، شناسایی چندورودی - چندخروجی، دینامیک پهپاد، شناسایی فضای حالت.

banazadeh@sharif.edu  
nobahari@sharif.edu  
yseifouri@ae.sharif.edu

## ۱. مقدمه

با استفاده از داده‌های ورودی و خروجی آن، یک راه حل مناسب است. روش های مختلفی برای شناسایی سیستم های دینامیکی وجود دارد که می توان آن ها را از جهات مختلف مانند شناسایی خطی یا غیرخطی، شناسایی پارامتری یا غیر پارامتری، شناسایی مبتنی بر ورودی - خروجی یا مبتنی بر خروجی و شناسایی حوزهی زمان یا حوزهی فرکانس تقسیم بندی کرد.<sup>[۱-۳]</sup> یکی از روش های شناسایی سیستم های دینامیکی، استفاده از ابزار شبکهی عصبی است که در حالت کلی می تواند در هر یک از تقسیم بندی های فوق قرار گیرد. در این پژوهش، از یک شبکهی عصبی خطی برای شناسایی دینامیک پرنده در حوزهی زمان به صورت خطی، پارامتری، مبتنی بر داده های ورودی - خروجی آزمون پروازی و به صورت چندورودی - چندخروجی استفاده شده است.

در چند دهه ای اخیر، از شبکه های عصبی برای شناسایی سیستم های دینامیکی مختلف استفاده شده است.<sup>[۲-۷]</sup> همچنین، استفاده از شبکه های عصبی در شناسایی سیستم های هوافضا رشد چشمگیری داشته است. در برخی از مطالعات از یک

یکی از مهم ترین فعالیت ها در توسعهی یک سیستم جدید یا ارتقاء یک سیستم موجود، مدل سازی و شبیه سازی آن است. با داشتن یک مدل دقیق و نیز شبیه سازی مناسب، می توان عملکرد سیستم های هر چند پیچیده را بررسی و پیش بینی کرد. علی رغم این که دینامیک بسیاری از سیستم های هوافضایی به راحتی قابل مدل سازی است، ولی تعیین دقیق پارامترهای مدل سیستم کماکان نیازمند صرف وقت و هزینه است. به خصوص در مورد وسایل پرنده، انجام محاسبه ی نیروها و گشتاورهای آیرودینامیکی و پیش رانشی وارد به آن به سادگی امکان پذیر نیست. بسیاری از نرم افزارهای موجود برای این کار نیز در مورد وسایل پرنده ی سبک (که بعضاً دینامیک پیچیده و سرعت پروازی کمی دارند)، فاقد دقت کافی است. استفاده از آزمون های تجربی و محاسبات عددی نیز از نظر زمان و هزینه مقرون به صرفه نیست؛ بنابراین، شناسایی دینامیک پرنده

\* نویسنده مستقر

تاریخ: دریافت ۱۶/۲/۱۳۹۶، اصلاحیه ۳۰/۵/۱۳۹۶، پذیرش ۱۶/۸/۱۳۹۶.

DOI: 10.24200/J40.2019.20840



شکل ۱. پرنده بدون سرنشین وایو.

جدول ۱. مشخصات فنی پرنده بدون سرنشین وایو.

دهانه‌ی بال	۳ m	سرعت کروز	۱۴۰ km/h
طول	۱/۸ m	مداومت پروازی	۱ h
ارتفاع	۹۵ cm	وزن بیشینه	۱۵ kg
موتور	۳ hp	سقف پرواز	۴۰۰۰ m

در مجموع ۱۱ حالت). این مدل برای شبیه‌سازی نرم‌افزاری دینامیک پرنده مناسب است. لازم به ذکر است که زوایای جریان در پرنده وایو اندازه‌گیری نمی‌شود و از تخمین آن‌ها با استفاده از داده‌های آزمون پرواز، در این پژوهش استفاده شده است. در بخش دوم این پژوهش، مشخصات پرنده مورد بررسی ارائه می‌شود. در بخش سوم، توضیحات مختصری در مورد شبکه‌های عصبی، شبکه‌ی مورد استفاده در این پژوهش، و نیز روش SSEST داده می‌شود. در بخش چهارم، جزئیات شناسایی بیان می‌شود. در بخش پنجم نتایج شناسایی ارائه و با نتایج روش SSEST مقایسه می‌شود. نهایتاً در بخش ششم نتایج کلی این پژوهش ارائه می‌شود.

## ۲. مشخصات پهپاد وایو

پرنده‌ی بدون سرنشین وایو، توسط دفتر فناوری هدایت و کنترل دانشگاه صنعتی شریف طراحی و ساخته شده است (شکل ۱). وایو در آموزش خلبانی هواپیماهای بدون سرنشین، آزمایشات پروازی سیستم‌ها و الگوریتم‌های هدایت و کنترل، مأموریت‌های شناسایی، عکس‌برداری و فیلم‌برداری تا ارتفاع ۴۰۰۰ متر از سطح دریا قابل استفاده است. این پرنده دارای دو خدمه (خلبان از راه دور و کمک‌خلبان) و دارای مداومت پروازی یک ساعته است. وایو توانایی حمل بار مفید تا سه کیلوگرم را دارد و برای ساخت آن تماماً از مواد کامپوزیت استفاده شده است. به طور خلاصه مشخصات فنی وایو در جدول ۱ است.<sup>[۱۹]</sup>

## ۳. روش‌های شناسایی مورد استفاده در این پژوهش

در این بخش، در مورد روش‌های مورد استفاده برای شناسایی دینامیک پرنده توضیح داده می‌شود.

### ۱.۳. شناسایی با استفاده از شبکه‌ی عصبی خطی

شبکه‌ی عصبی ابزاری برای پردازش داده‌های ورودی و تولید خروجی مناسب است. این ابزار با الهام از عملکرد مغز انسان توسعه یافته است. المان‌های اصلی در یک

شبکه‌ی عصبی با یک لایه‌ی پنهان به عنوان تخمین‌گر داده‌های آزمون پروازی استفاده شده است.<sup>[۸]</sup> از این تخمین‌گر غیرخطی برای تشخیص افت عملکرد تجهیزات به کار رفته در آزمون پرواز استفاده شده است. محققین از سه شبکه‌ی عصبی بازگشتی برای شناسایی دینامیک یک بالگرد استفاده و عملکرد آن‌ها را مقایسه کرده‌اند.<sup>[۹]</sup> آن‌ها از یک شبکه‌ی عصبی با یک لایه‌ی پنهان<sup>[۱۰]</sup> و نیز از یک شبکه‌ی عصبی پرسپترون چندلایه برای شناسایی دینامیک بالگرد مدل<sup>[۱۱]</sup> استفاده می‌کنند. در مطالعه‌ی دیگر از یک شبکه‌ی پایه‌ی شعاعی (RBN)<sup>۳</sup> برای شناسایی دینامیک پرنده، با استفاده از داده‌های شبیه‌سازی پرواز، استفاده شده،<sup>[۱۲]</sup> و سپس عملکرد مدل شناسایی شده، و با انجام آزمون‌های مختلف در شبیه‌ساز، بررسی شده است. همچنین از داده‌های آزمون پروازی برای شناسایی دینامیک مود طولی یک پرنده توربوپراپ با کمک شبکه‌ی عصبی استفاده شده است؛<sup>[۱۳]</sup> شبکه‌ی مورد استفاده در این مورد، یک شبکه‌ی عصبی دولایه است که در لایه‌ی اول از تابع فعال‌سازی هیپربولیک و در لایه‌ی دوم از تابع فعال‌سازی خطی استفاده شده است. از شبکه‌ی عصبی NNARX نیز برای شناسایی دینامیک پرنده در فاز کروز (در سرعت‌ها و ارتفاع‌های پروازی مختلف و بر اساس داده‌های شبیه‌ساز پرواز) استفاده شده است.<sup>[۱۴]</sup> محققین ضمن استفاده از شبکه‌ی عصبی برای شناسایی دینامیک هواپیما،<sup>[۱۵]</sup> کوشیده‌اند تا به کمک این دینامیک، رفتار پرنده در سایر رژیم‌های پروازی را پیش‌بینی کنند. در این مطالعات، شناسایی سیستم به صورت جعبه سیاه انجام شده است. یعنی سعی شده خروجی شبکه (بدون اطلاع از دینامیک درونی) بر خروجی سیستم (حاصل از آزمون پرواز یا شبیه‌ساز) منطبق شود. این مدل شناسایی برای شبیه‌سازی و پیش‌بینی رفتار سیستم و نیز تشخیص افت عملکرد سیستم مناسب است؛ در حالی که در برخی موارد (مانند طراحی کنترل‌کننده‌ی مناسب)، شناسایی دینامیک سیستم به شکل توابع تبدیل یا فضای حالت کاربرد بیشتری دارد. در برخی مطالعات از یک شبکه‌ی عصبی تک‌لایه‌ی خطی و فاقد بایاس برای شناسایی دینامیک پرنده استفاده شده است.<sup>[۱۶، ۱۷]</sup> در این مطالعات دینامیک طولی و عرضی پرنده در فرم فضای حالت و به صورت مجزا شناسایی شده است. همچنین برای تعیین وزن‌های شبکه از روش بیشترین کاهش<sup>۴</sup> استفاده می‌کنند. ماتریس وزن شبکه که در این حالت به دست می‌آید، همان ماتریس‌های فضای حالت سیستم است. حالت‌های سیستم در این مراجع شامل نرخ سرعت‌های زاویه‌ی پرنده، زوایای رول و پیچ، اندازه سرعت و زوایای جریان (در مجموع هشت حالت) است.

در پژوهش حاضر، دینامیک پرنده بدون سرنشین وایو<sup>۵</sup> (شامل دینامیک طولی و عرضی)، به صورت کوپل و با استفاده از داده‌های آزمون پروازی شناسایی می‌شود. بال این پرنده از نوع چندسطحی<sup>۶</sup> است و قرارگیری سطوح کنترلی ایلرون در انتهای بال، باعث کوپلینگ بین حرکت رول و یاو پرنده می‌شود. همچنین، تکانه‌ی زاویه‌ی بخش دوار سیستم پیشران (مجموعه‌ی موتور و ملخ) باعث کوپلینگ دینامیک طولی و عرضی می‌شود.<sup>[۱۸]</sup> دینامیک پرنده در دو مدل شناسایی می‌شود. در مدل اول، حالت‌های سیستم شامل سرعت‌های زاویه‌ی، زوایای رول و پیچ و شتاب‌های غیرگرانشی وارد به پرنده (در مجموع هشت حالت) است. در این مدل (برخلاف مدل استفاده شده در مطالعات<sup>[۱۶، ۱۷]</sup>) اندازه سرعت و زوایای جریان (شامل زاویه‌ی حمله<sup>۷</sup> و زاویه‌ی سرش جانبی<sup>۸</sup>) در نظر گرفته نمی‌شود. این مدل برای طراحی کنترل‌کننده‌ی پرنده مناسب‌تر است؛ چرا که معمولاً زوایای جریان (به‌خصوص در پرنده‌های سبک) اندازه‌گیری نمی‌شود و برای محاسبه‌ی آن لازم است از مشاهده‌گر استفاده شود. این در حالی است که استفاده از حس‌گرهای اندازه‌گیری سرعت‌های زاویه‌ی و شتاب‌های بدنی (حتی در سبک‌ترین پرنده‌ها) متداول است. در مدل دوم، علاوه بر هشت حالت فوق، اندازه سرعت و زوایای جریان نیز در نظر گرفته می‌شود

برای آموزش شبکه (تنظیم ماتریس وزن و بردار بایاس) از الگوریتم بهینه‌سازی بیشترین کاهش استفاده شده است. برای این کار، تابع هزینه مطابق رابطه ۴ تعریف می‌شود:

$$\hat{F} = e^T(k)e(k) \quad (4)$$

که در آن  $e(k)$  بردار خطا (بین خروجی شبکه و خروجی مطلوب)، و  $\hat{F}$  تخمین میانگین مربعات خطا در تکرار  $k$ م آموزش شبکه است. باید توجه داشت که در محاسبات برخط، محاسبه‌ی میانگین مربعات خطا ممکن نیست. بنابراین، در صورتی که شناسایی دینامیک به صورت برخط مد نظر باشد، از تخمین میانگین مربعات خطا استفاده می‌شود. در رابطه‌ی ۴ فرض بر آن است که میانگین مربعات خطا در هر گام، برابر با مربعات خطا در همان گام است. در این حالت، به روز رسانی پارامترهای شبکه براساس گرادینان لحظه‌ی و از رابطه‌ی ۵ محاسبه می‌شود:

$$x_{ij}(k+1) = x_{ij}(k) - \alpha_1 \frac{\partial \hat{F}(k)}{\partial x_{ij}(k)} \quad (5)$$

که در آن  $x_{ij}$  آرایه‌های ماتریس  $X$  (ترکیب ماتریس وزن و بردار بایاس) در تکرار  $k$ م آموزش شبکه، و  $\alpha_1$  نرخ یادگیری (یک عدد مثبت) است. هرچه نرخ یادگیری کم‌تر باشد، الگوریتم دیرتر به جواب بهینه (بهینه‌ی کلی یا مقطعی) می‌رسد. از طرفی، در صورتی که نرخ یادگیری زیاد باشد، ممکن است بهینه‌سازی واگرا شود. در شرایطی که تابع هزینه مشخص و به فرم کوادراتیک باشد، می‌توان نرخ یادگیری را به‌گونه‌ی تعیین کرد که هم‌گرایی بهینه‌سازی (آموزش شبکه) تضمین شود.<sup>[۲۰]</sup> در این پژوهش، نرخ یادگیری با سعی و خطا تعیین شده است.

### ۲.۳. روش شناسایی SSEST

الگوریتم SSEST یک روش شناسایی چندورودی - چندخروجی برای شناسایی دینامیک سیستم در فرم فضای حالت است. این الگوریتم تکراری بر اساس کمیته‌سازی خطای پیش‌بینی (خطای بین خروجی واقعی و خروجی پیش‌بینی) عمل می‌کند. برای شناسایی با استفاده از الگوریتم SSEST می‌توان از داده‌های حوزه‌ی زمان یا حوزه‌ی فرکانس استفاده کرد.<sup>[۲۱، ۲۲]</sup> در این پژوهش، برای استفاده از روش SSEST، از نرم‌افزار متلب (جعبه‌ابزار شناسایی سیستم) استفاده شده است که در آن، الگوریتم SSEST (به صورت پیش‌فرض) برای حدس اولیه‌ی دینامیک سیستم از روش «الگوریتم عددی برای شناسایی زیرفضا (NFSID)»<sup>[۲۰]</sup> استفاده می‌کند که خود روش دیگری برای تخمین دینامیک سیستم در فرم فضای حالت است.<sup>[۲۱]</sup> خروجی این الگوریتم، ماتریس‌های فضای حالت سیستم است:

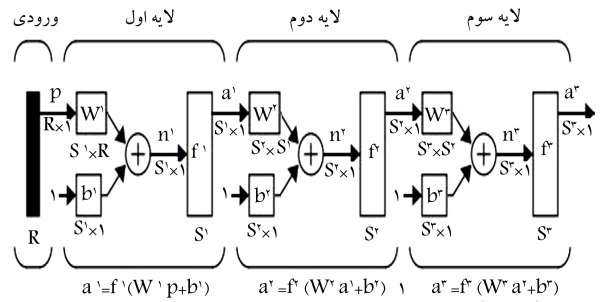
$$\dot{x}(t) = Ax(t) + Bu(t) + Ke(t) \quad (6)$$

$$y(t) = Cx(t) + Du(t) \quad (7)$$

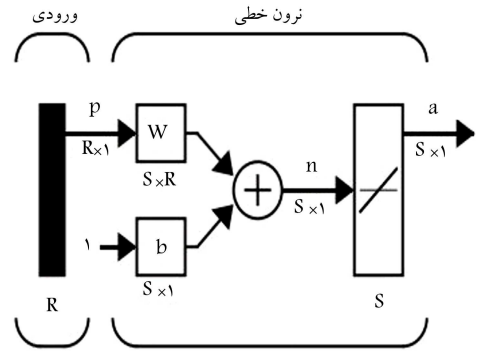
که در آن  $x$  بردار حالت‌های سیستم،  $y$  بردار خروجی سیستم،  $u$  بردار ورودی سیستم،  $e$  بردار اغتشاش ورودی به سیستم و  $t$  نشان‌دهنده‌ی زمان است. در این پژوهش برای شناسایی دینامیک پرنده از الگوریتم SSEST با تنظیمات پیش‌فرض آن (در متلب b ۲۰۱۴ R) استفاده شده است.

### ۴. جزئیات شناسایی دینامیک پرنده

دینامیک پرنده به دو صورت شناسایی می‌شود. در مدل اول، متغیرهای حالت شامل سرعت‌های زوایه‌ی  $(p, q, r)$ ، زوایای رول و پیچ  $(\phi, \theta)$  شتاب‌های غیرگرانشی



شکل ۲. یک شبکه‌ی عصبی چندلایه.<sup>[۲۰]</sup>



شکل ۳. یک شبکه‌ی خطی تک‌لایه.<sup>[۲۰]</sup>

شبکه‌ی عصبی شامل داده‌های ورودی، ماتریس‌های وزن و بایاس، تابع فعال‌سازی و خروجی است. یک شبکه‌ی چندلایه از کنار هم قرار گرفتن چند شبکه‌ی تک‌لایه به صورت سری ایجاد می‌شود. در این حالت، خروجی هر لایه، ورودی لایه‌ی بعدی خواهد بود. امروزه، با توجه به توسعه‌ی سخت‌افزار و نرم‌افزارهای محاسباتی، استفاده از شبکه‌های عصبی در بسیاری از حوزه‌ها رایج شده و شبکه‌های بسیاری برای انجام فعالیت‌های مختلف معرفی شده است.<sup>[۲۰]</sup> در شکل ۲ یک شبکه‌ی عصبی چندلایه نمایش داده شده است. در هر لایه از یک شبکه‌ی عصبی، ماتریس وزن ( $W$ ) در بردار ورودی ( $p$ ) ضرب و با بردار بایاس ( $b$ ) جمع می‌شود و در نتیجه، ورودی خالص  $n$  تولید می‌شود. با اعمال تابع فعال‌سازی بر ورودی خالص، خروجی یک لایه‌ی شبکه تولید می‌شود. در یک شبکه‌ی چندلایه، ورودی اولین لایه‌ی همان ورودی شبکه و خروجی آخرین لایه‌ی همان خروجی شبکه است.<sup>[۲۰]</sup> در این پژوهش برای شناسایی دینامیک پرنده از یک شبکه‌ی عصبی خطی استفاده شده است. در شکل ۳ یک شبکه‌ی خطی تک‌لایه نشان داده شده است. خروجی این شبکه مطابق روابط ۱ و ۲ محاسبه می‌شود:

$$n = Wp + b \quad (1)$$

$$a = f(n) = n \quad (2)$$


این شبکه برای مدل کردن رفتارها و پدیده‌های خطی کاربرد دارد. لازم به ذکر است که بردار بایاس را می‌توان به صورت یک بردار وزن در نظر گرفت که در ورودی واحد ضرب می‌شود. بنابراین، می‌توان دو رابطه‌ی ۱ و ۲ را چنین بازنویسی کرد:

$$a = \begin{bmatrix} W & b \\ 1 \end{bmatrix} z = Xz \quad (3)$$


### ۱.۵. مدل اول شناسایی دینامیک پرنده

چنانچه با نرخ یادگیری  $5 - l_e = a_1$ ، شبکه‌ی عصبی (با استفاده از بخشی از داده‌های آزمون پروازی اول به مدت  $5^\circ$  ثانیه)، آموزش داده شود، بخش‌های ماتریس وزن شبکه (شامل ماتریس‌های حالت  $G$  و ورودی  $H$  مربوط به مدل اول شناسایی) عبارت خواهد بود از: با بررسی دریاچه‌های این دو ماتریس ( $G$  و  $H$ )، کویلینگ بین حالت‌های مختلف پرنده قابل مشاهده است. برای مثال، غیر صفر بودن  $G(1, 2)$  و  $H(1, 2)$ ، به ترتیب نشان‌دهنده‌ی تأثیر نرخ پیچ و انحراف الویتور بر نرخ رول است. تأثیر نرخ پیچ بر نرخ رول (کویلینگ رول و پیچ)، ناشی از اندازه حرکت زاویه‌ی موتور و ملخ است.<sup>[۱۸]</sup> حال با این ماتریس‌های ورودی و حالت، دینامیک پرنده (با استفاده از داده‌های آزمون پروازی اول به مدت  $15^\circ$  ثانیه) شبیه‌سازی می‌شود. نتایج این شبیه‌سازی، به همراه داده‌های آزمون پروازی و نتایج شبیه‌سازی دینامیک شناسایی شده به روش SSEST، در شکل‌های ۴ تا ۱۱ آمده است. در این شکل‌ها، تنها بخشی از زمان پرواز نشان داده شده است تا مقایسه نتایج بهتر انجام شود.

با بررسی این شکل‌ها، مشاهده می‌شود که شناسایی دینامیک پرنده به کمک شبکه‌ی عصبی خطی به خوبی انجام شده و خروجی سیستم شناسایی شده مشابه داده‌های آزمون پروازی است. همچنین مشاهده می‌شود که شناسایی سیستم به کمک این شبکه قابل مقایسه با الگوریتم SSEST و حتی بهتر از آن است.<sup>[۱۱]</sup> همچنین مشاهده می‌شود که در سیستم شناسایی شده، اثرات نویز (نوسان داده‌ها با فرکانس بالا) تا حد خوبی تضعیف شده و در خروجی سیستم شناسایی شده ظاهر



شکل ۴. نرخ رول پرنده (شامل خروجی آزمون پروازی اول، شبکه‌ی عصبی خطی و SSEST).



شکل ۵. نرخ پیچ پرنده (شامل خروجی آزمون پروازی اول، شبکه‌ی عصبی خطی و SSEST).

وارد به پرنده در دستگاه بدنی  $(a_x, a_y, a_z)$  است. خروجی‌های سیستم نیز مشابه حالت‌های آن در نظر گرفته می‌شود (ماتریس خروجی، یک ماتریس همانی است). ورودی‌های کنترلی سیستم در این مدل شامل انحراف سطح کنترلی ایلرون، الویتور و رادرو مقدار تراتل موتور است  $(\delta_a, \delta_e, \delta_r, \delta_{th_r})$ . بنابراین در فرم فضای حالت زمان گسسته می‌توان نوشت:

$$\mathbf{x}(k+1) = \mathbf{G}\mathbf{x}(k) + \mathbf{H}\mathbf{u}(k) \quad (8)$$

$$\mathbf{y}(k+1) = \mathbf{x}(k+1) \quad (9)$$

در این دو رابطه  $\mathbf{u} = [\delta_a \delta_e \delta_r \delta_{th_r}]$  و  $\mathbf{x} = \mathbf{y} = [p \ q \ r \ \phi \ \theta \ a_x \ a_y \ a_z]$  است. همچنین  $G$  ماتریس حالت و  $H$  ماتریس ورودی است. این دو رابطه را می‌توان چنین زیر بازنویسی کرد:

$$\mathbf{a}(k+1) = \mathbf{W}\mathbf{p}(k) \quad (10)$$

که در آن  $\mathbf{p}(k) = [\mathbf{x}^T(k) \ \mathbf{u}^T(k)]^T$  و  $\mathbf{W} = [\mathbf{G} \ \mathbf{H}]$ ،  $\mathbf{a}(k+1) = \mathbf{x}(k+1)$  است. بنابراین با استفاده از شبکه‌ی خطی تک‌لایه می‌توان دینامیک سیستم را در فرم فضای حالت شناسایی کرد. در این حالت، ماتریس وزن شبکه از ماتریس فضای حالت و ماتریس ورودی سیستم تشکیل شده است. چنانچه برای شبکه‌ی خطی، یک بردار بایاس در نظر گرفته شود، با آموزش شبکه مقدار آن به مقادیر نزدیک به صفر هم‌گرا می‌شود که ناشی از خطای الگوریتم بهینه‌سازی بیشترین کاهش است. بنابراین، بهتر است شبکه را فاقد بایاس در نظر بگیریم.

مدل دوم شناسایی نیز مشابه مدل اول است، با این تفاوت که اندازه سرعت و زوایای جریان  $(\beta, a, V)$  نیز به حالت‌های سیستم اضافه می‌شود. لازم به ذکر است که در پرنده‌ی وایو (همانند سایر پرنده‌های سبک)، زوایای جریان اندازه‌گیری نمی‌شود؛ این پارامترها از روی سایر داده‌های آزمون پروازی تخمین زده شده‌اند. مدل اول شناسایی برای طراحی کنترل‌کننده‌ی پرنده مناسب است زیرا تمامی حالت‌های سیستم در این حالت، به وسیله‌ی یک سیستم تعیین وضعیت قابل اندازه‌گیری است. استفاده از این مدل برای شبیه‌سازی نرم‌افزاری پرنده مناسب نیست؛ چرا که با وجود بایاس سنسور و اغتشاش در داده‌های پروازی (و نیز خطای کم در تعیین ماتریس‌های  $G$  و  $H$ )، محاسبه‌ی بردار سرعت پرنده با خطای زیادی همراه خواهد بود. توجه داشته باشیم که محاسبه‌ی سرعت پرنده با انتگرال‌گیری از معادلات دینامیکی (تابع بردار شتاب، سرعت‌های زاویه‌ی و زوایای اولیه) به دست می‌آید.<sup>[۱۳]</sup> برای شبیه‌سازی نرم‌افزاری پرنده می‌توان از مدل دوم استفاده کرد.



برای شناسایی دینامیک پرنده از داده‌های دو آزمون پروازی استفاده می‌شود. در آزمون اول، داده‌های پروازی پرنده به مدت  $15^\circ$  ثانیه ذخیره شده است. با انتخاب بخشی از این داده‌ها (به مدت  $5^\circ$  ثانیه)، شناسایی دینامیک پرنده انجام می‌شود. سپس با استفاده از کل داده‌های پروازی، کیفیت شناسایی ارزیابی می‌شود. در مرحله‌ی بعد، با استفاده از داده‌های آزمون پروازی دوم (به مدت  $20^\circ$  ثانیه)، کیفیت شناسایی دوباره ارزیابی می‌شود.

### ۵. نتایج شناسایی دینامیک پرنده

در این بخش، نتایج شناسایی دینامیک پرنده وایو با استفاده از شبکه‌ی عصبی خطی ارائه و با نتایج روش SSEST مقایسه می‌شود.



$$G = \begin{bmatrix} 0,9238 & -0,2508 & 0,4732 & -0,1923 & -0,0742 & 1,1915 & 2,7642 & 0,1863 \\ 0,0023 & 0,8517 & 0,0054 & 0,0102 & -0,0007 & -2,6246 & -0,2083 & 0,0285 \\ -0,0265 & 0,0104 & 0,9166 & 0,0238 & -0,0228 & -0,2550 & -1,0036 & -0,0882 \\ 0,0467 & -0,0124 & 0,0215 & 0,9922 & -0,0129 & 0,0326 & 0,1084 & 0,0095 \\ 0,0006 & 0,0412 & 0,0124 & 0,0119 & 0,9963 & -0,0940 & 0,0196 & -0,0035 \\ 0,0000 & 0,0044 & -0,0041 & -0,0001 & 0,0098 & 0,7301 & -0,248 & -0,0011 \\ -0,0031 & 0,0005 & 0,0169 & -0,0042 & -0,0012 & -0,0259 & 0,9000 & -0,0043 \\ -0,0037 & 0,0002 & 0,0118 & -0,0131 & 0,0103 & 0,7326 & 0,0639 & 0,9776 \end{bmatrix}$$

$$H = \begin{bmatrix} 1,2590 & 0,1767 & -0,0990 & -0,9518 \\ 0,0022 & 1,6545 & 0,2778 & 0,2285 \\ -0,1080 & 0,0317 & 0,1307 & 0,2153 \\ 0,0482 & -0,0021 & 0,0272 & -0,0494 \\ -0,0047 & 0,0072 & 0,0229 & 0,0816 \\ 0,0007 & 0,0099 & 0,0133 & -0,0119 \\ -0,0049 & 0,0097 & 0,0053 & 0,0362 \\ 0,0144 & -0,4286 & -0,0327 & -0,1753 \end{bmatrix}$$




شکل ۸. زاویه‌ی پیچ پرنده (شامل خروجی آزمون پروازی اول، شبکه‌ی خطی و SSEST).

شکل ۶. نرخ یابو پرنده (شامل خروجی آزمون پروازی اول، شبکه‌ی خطی و SSEST).



شکل ۹. شتاب غیر گرانشی طولی پرنده (شامل خروجی آزمون پروازی اول، شبکه‌ی خطی و SSEST).

شکل ۷. زاویه‌ی رول پرنده (شامل خروجی آزمون پروازی اول، شبکه‌ی خطی و SSEST).



شکل ۱۲. جذر میانگین مربعات خطای زاویه پیچ در دو روش شبکه‌ی خطی و SSEST.

جدول ۲. ضرایب نابرابری Theil برای بررسی کیفیت شناسایی دینامیک سیستم (مدل اول) مربوط به آزمون پروازی اول.


SSEST	شبکه‌ی عصبی	سیستم شناسایی شده
۰٫۷۸	۰٫۳۹	$p$
۰٫۵۴	۰٫۲۳	$q$
۰٫۶۱	۰٫۳۵	$r$
۰٫۳۳	۰٫۱۹	$\phi$
۰٫۶۱	۰٫۵۲	$\theta$
۰٫۵۳	۰٫۱۴	$a_x$
۰٫۵۹	۰٫۳۹	$a_y$
۰٫۳۶	۰٫۲۷	$a_z$

دارد و نه مناسب است؛ چرا که می‌تواند بیان‌گر شناسایی حافظه‌دار باشد که نامطلوب است (جدول ۲). با توجه به داده‌های این جدول، مشاهده می‌شود که ضریب نابرابری Theil برای خروجی دینامیک پرندگی، که با کمک شبکه‌ی عصبی شناسایی شده است، نزدیک به صفر و مطلوب است (البته کیفیت شناسایی زاویه‌ی پیچ نسبت به سایر خروجی‌ها کم‌تر است). همچنین مشاهده می‌شود که مقدار این ضریب برای شناسایی به کمک شبکه‌ی عصبی نسبت به شناسایی به روش SSEST کم‌تر است.


#### ۲.۵. مدل دوم شناسایی دینامیک پرندگی

مشابه قبل، با استفاده از بخشی از داده‌های آزمون پروازی اول به مدت ۵ ثانیه و با نرخ یادگیری  $5 \times 10^{-5}$ ، شبکه‌ی عصبی آموزش داده می‌شود. در این حالت، بخش‌های ماتریس وزن شبکه (شامل ماتریس‌های حالت  $G$  و ورودی  $H$  مربوط به مدل دوم شناسایی) عبارت خواهد بود از:

حال دینامیک پرندگی با استفاده از ماتریس‌های فوق شبیه‌سازی می‌شود. نتایج این شبیه‌سازی به همراه داده‌های آزمون پروازی و نتایج شبیه‌سازی دینامیک شناسایی شده به روش SSEST، در شکل‌های ۱۳ تا ۱۵ آمده است. لازم به ذکر است که سایر خروجی‌های سیستم در این مدل شناسایی مشابه بخش قبل است. بنابراین تنها نمودار مربوط به سه خروجی آخر (یعنی اندازه سرعت و زوایای جریان) نشان داده شده است. در این شکل‌ها نیز، تنها بخشی از زمان پرواز ارائه شده تا مقایسه‌ی نتایج بهتر انجام شود.



شکل ۱۰. شتاب غیر گرانشی عرضی پرندگی (شامل خروجی آزمون پروازی اول، شبکه‌ی خطی و SSEST).



شکل ۱۱. شتاب غیر گرانشی عمودی پرندگی (شامل خروجی آزمون پروازی اول، شبکه‌ی خطی و SSEST).

نشده است. این خود نشان می‌دهد که شبکه‌ی عصبی داده‌های ورودی و خروجی را حفظ نکرده و در عوض، دینامیک واقعی سیستم را مدل کرده است. برای بررسی سرعت هم‌گرایی دو روش در تخمین دینامیک سیستم، جذر میانگین مربعات<sup>۱۲</sup> خطای زاویه‌ی پیچ (به عنوان نمونه) بر حسب دوره<sup>۱۳</sup> داده‌های تخمین، در شکل ۱۲ ارائه شده است. مشاهده می‌شود که آموزش شبکه برای تخمین دینامیک پرندگی، پس از ۶ دوره هم‌گرا شده است.


مشابه مطالعات پیشین<sup>۱۷</sup>، از معیار ضریب نابرابری Theil نیز برای مقایسه‌ی کیفیت شناسایی استفاده می‌کنیم. این ضریب از رابطه‌ی ۱۱ محاسبه می‌شود:

$$Th = \frac{\sqrt{\sum (y(k) - \tilde{y}(k))^2}}{\sqrt{\sum (y(k))^2} + \sqrt{\sum (\tilde{y}(k))^2}} \quad (11)$$

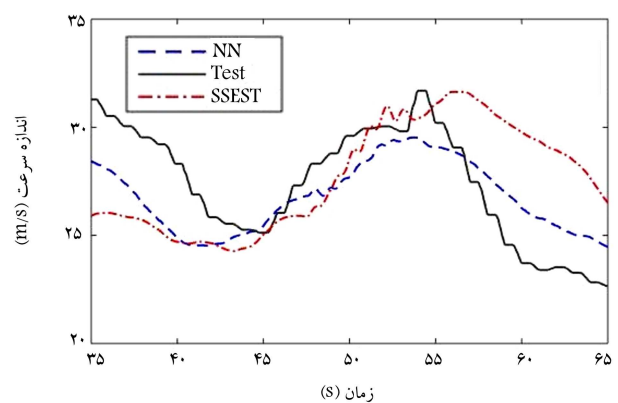
که در آن  $y$  داده آزمون پروازی و  $\tilde{y}$  خروجی دینامیک شناسایی شده است. ضریب Theil برای تمامی خروجی‌های سیستم و بر اساس کل داده‌های آزمون پروازی (۱۵۰ ثانیه در آزمون پروازی اول) محاسبه می‌شود. این ضریب در واقع بیان‌گر ریشه‌ی میانگین مربعات خطا (RMSE) است که نرمال شده است. بدیهی است هر چه مقدار این ضریب کم‌تر باشد، درصد اختلاف بین خروجی سیستم شناسایی شده و داده‌های آزمون پروازی کم‌تر است. البته صفر شدن این کمیت نه ضرورتی

$$G = \begin{bmatrix} 0,9777 & -0,5310 & 0,3875 & -0,2710 & 0,1536 & 0,1401 & 1,3330 & -0,6549 & -0,2175 & -0,7687 & 0,0789 \\ 0,0122 & 1,0051 & 0,0074 & 0,0079 & -0,0839 & -0,2002 & -0,1072 & 0,2696 & 0,0813 & -0,0168 & 0,0433 \\ -0,0372 & 0,0039 & 0,8953 & 0,0516 & -0,0365 & -0,0147 & -0,0523 & -0,0716 & -0,0070 & 0,1400 & -0,1614 \\ 0,0542 & -0,0171 & 0,0254 & 0,9855 & -0,0022 & 0,0096 & -0,0070 & -0,0215 & -0,0049 & -0,0289 & 0,0083 \\ 0,0015 & 0,0529 & 0,0136 & 0,0124 & 0,9853 & -0,0083 & 0,0470 & 0,0168 & 0,0099 & -0,0028 & 0,0200 \\ -0,0002 & 0,0028 & -0,0019 & -0,0017 & 0,0278 & 0,0321 & -0,0167 & -0,0068 & -0,0137 & 0,0170 & -0,0696 \\ 0,0004 & -0,0173 & 0,0319 & -0,0315 & 0,0125 & -0,0025 & 0,4058 & -0,0845 & 0,0021 & -0,1376 & 0,1954 \\ -0,0069 & -0,1066 & -0,0044 & -0,0106 & 0,0428 & 0,0624 & -0,0431 & 0,7528 & -0,0721 & -0,0182 & -0,0353 \\ -0,0002 & -0,0052 & -0,0004 & 0,0007 & -0,0032 & 0,0091 & -0,0005 & -0,0160 & 0,9941 & 0,0052 & -0,0113 \\ 0,0029 & -0,0009 & -0,0076 & -0,0129 & 0,0165 & 0,0115 & -0,0877 & -0,0610 & 0,0098 & 0,7024 & 0,0018 \\ -0,0024 & -0,0007 & 0,0151 & 0,0189 & 0,0014 & -0,0632 & 0,1803 & 0,0232 & -0,0125 & 0,1297 & 0,6111 \end{bmatrix}$$

$$H = \begin{bmatrix} 0,9143 & -0,2643 & 0,0807 & -0,0374 \\ -0,1650 & 0,9214 & 0,1468 & 0,0323 \\ -0,0848 & 0,0386 & -0,0164 & 0,0295 \\ 0,0495 & -0,0556 & 0,0349 & -0,0502 \\ -0,0160 & -0,0036 & 0,0680 & -0,0344 \\ 0,0032 & 0,0277 & 0,0030 & 0,0415 \\ -0,0033 & -0,0053 & -0,0812 & -0,0441 \\ 0,0420 & -0,1382 & 0,0111 & -0,0057 \\ -0,0011 & -0,0058 & 0,0055 & 0,0494 \\ -0,0207 & -0,0350 & -0,0376 & 0,0028 \\ -0,0147 & 0,0044 & -0,0138 & 0,0460 \end{bmatrix}$$




شکل ۱۵. زاویه سرش جانبی (شامل تخمین خروجی آزمون پروازی اول، شبکه‌ی خطی و SSEST).




شکل ۱۳. اندازه سرعت پرنده (شامل تخمین خروجی آزمون پروازی اول، شبکه‌ی خطی و SSEST).

مشاهده می‌شود که کیفیت شناسایی با استفاده از شبکه‌ی عصبی خطی، نسبت به مدل قبل کم‌تراست، اگرچه کیفیت شناسایی آن نسبت به روش SSEST بهتر است. دقت شود که دینامیک این سه خروجی نسبت به سایر خروجی‌ها کندتر است که با تخمین (بر اساس سایر داده‌های آزمون پرواز) محاسبه شده‌اند. بنابراین، می‌توان گفت که این افت کیفیت شناسایی دور از انتظار نیست. مشابه بخش قبل، برای مقایسه‌ی کیفیت شناسایی از ضریب نابرابری Theil نیز استفاده می‌کنیم. ضریب نابرابری Theil در این مدل شناسایی در جدول ۳ آمده است. مشاهده می‌شود که در مورد هشت خروجی اول، مقادیر این جدول بسیار نزدیک به مقادیر جدول ۲ است. بنابراین می‌توان گفت که دینامیک هشت خروجی اول به خوبی شناسایی شده است. در مورد سرعت پرنده و زوایای جریان نیز می‌توان گفت که خروجی سیستم شناسایی شده به کمک شبکه‌ی عصبی انطباق




شکل ۱۴. زاویه حمله (شامل تخمین خروجی آزمون پروازی اول، شبکه‌ی خطی و SSEST).





شکل ۱۶. نرخ رول پرندگی (شامل خروجی آزمون پروازی دوم و شبکه‌ی خطی).



شکل ۱۷. نرخ پیچ پرندگی (شامل خروجی آزمون پروازی دوم و شبکه‌ی خطی).

جدول ۵. ضرایب نابرابری Theil برای بررسی کیفیت شناسایی دینامیک سیستم به کمک شبکه‌ی عصبی (مدل دوم) مربوط به آزمون پروازی دوم.

خروجی سیستم	ضریب Theil	خروجی سیستم	ضریب Theil
$p$	۰٫۲۰	$a_x$	۰٫۳۵
$q$	۰٫۴	$a_y$	۰٫۳۲
$r$	۰٫۲۷	$a_z$	۰٫۱۵
$\phi$	۰٫۲۸	$V$	۰٫۱
$\theta$	۰٫۵۲	$\alpha$	۰٫۱۵
		$\beta$	۰٫۳۸

از نتایج شبکه‌ی عصبی با کیفیت کم‌تری (نسبت به مدل قبل) بر داده‌های آزمون پروازی دوم منطبق می‌شود. ضرایب نابرابری Theil در این حالت در جدول ۵ آمده است. از مقایسه‌ی اعداد این جدول با ستون دوم جدول ۳ مشاهده می‌شود که سه خروجی آخر دینامیک شناسایی شده، به خوبی توانسته است داده‌های آزمون پروازی دوم را مدل (پیش‌بینی) کند. به عنوان نمونه، نمودارهای مربوط به اندازه سرعت و زاویه حمله جریان در شکل‌های ۱۸ و ۱۹ ارائه شده است. لازم به ذکر است که در این پژوهش، کیفیت شناسایی اندازه سرعت نسبت به سایر حالت‌های پروازی پرندگی کم‌تر است؛ چرا که در آزمون پروازی اول (که شناسایی بر اساس آن صورت گرفته است)، سرعت پرندگی تغییر محسوس ندارد و تقریباً ثابت است. در واقع، ورودی متناظر با خروجی سرعت پرندگی (یعنی مقدار ترائل) تقریباً ثابت و دینامیک سرعت به خوبی تحریک نشده است.

جدول ۳. ضرایب نابرابری Theil برای بررسی کیفیت شناسایی دینامیک سیستم (مدل دوم) مربوط به آزمون پروازی اول.

سیستم شناسایی شده	شبکه‌ی عصبی	SSEST
$p$	۰٫۳۳	۰٫۷۵
$q$	۰٫۲۸	۰٫۵۴
$r$	۰٫۲۹	۰٫۵۷
$\phi$	۰٫۲۱	۰٫۳۳
$\theta$	۰٫۴۷	۰٫۶۶
$a_x$	۰٫۴۷	۰٫۵۱
$a_y$	۰٫۳۳	۰٫۵۹
$a_z$	۰٫۱۷	۰٫۳۸
$V$	۰٫۱۸	۰٫۴۳
$\alpha$	۰٫۲۲	۰٫۲۵
$\beta$	۰٫۳۶	۰٫۴۳

جدول ۴. ضرایب نابرابری Theil برای بررسی کیفیت شناسایی دینامیک سیستم به کمک شبکه‌ی عصبی (مدل اول) مربوط به آزمون پروازی دوم.

خروجی سیستم	ضریب Theil	خروجی سیستم	ضریب Theil
$p$	۰٫۳۳	$\theta$	۰٫۵۵
$q$	۰٫۲۷	$a_x$	۰٫۴۳
$r$	۰٫۳۸	$a_y$	۰٫۴۴
$\phi$	۰٫۲۸	$a_z$	۰٫۲۲

خوبی با نتایج آزمون دارد و عملکرد آن در مقایسه با روش SSEST بهتر است.

### ۳.۵. ارزیابی مجدد کیفیت شناسایی به کمک شبکه‌ی عصبی با

#### استفاده از داده‌های آزمون پروازی دوم

در این بخش با استفاده از داده‌های آزمون پروازی دوم، کیفیت شناسایی دینامیک پرندگی دوباره ارزیابی می‌شود. این کار فقط برای مدل شناسایی شده به کمک شبکه‌ی عصبی انجام می‌شود؛ چرا که هدف اصلی در این پژوهش شناسایی به کمک شبکه‌ی عصبی است (مقایسه‌ی عملکرد شناسایی به کمک شبکه‌ی عصبی با روش SSEST در دو بخش قبل انجام شد). چنانچه مدل اول شناسایی با استفاده از ورودی‌ها و شرایط اولیه آزمون پروازی دوم، شبیه‌سازی شود، خروجی سیستم با استفاده از نتایج شبکه‌ی عصبی با کیفیت خوبی بر داده‌های آزمون پروازی دوم منطبق می‌شود. ضرایب نابرابری Theil در این حالت در جدول ۴ آمده است.

با مقایسه‌ی اعداد این جدول با ستون دوم جدول ۲ مشاهده می‌شود که خروجی دینامیک شناسایی شده، به خوبی توانسته است داده‌های آزمون پروازی دوم را نیز مدل (پیش‌بینی) کند و شناسایی به خوبی انجام شده است. به عنوان نمونه، نمودارهای مربوط به نرخ رول و زاویه پیچ در شکل ۱۶ و ۱۷ ارائه شده است. چنانچه مدل دوم شناسایی را شبیه‌سازی کنیم، باز هم خروجی سیستم با استفاده



غیرگرانشی در دستگاه بدنی است. در مدل دوم، حالت‌های اندازهی سرعت و زوایای جریان نیز اضافه می‌شود. مقایسه‌ی خروجی‌های دینامیک شناسایی شده به کمک شبکه‌ی عصبی با داده‌های آزمون‌های پروازی نشان می‌دهد که شبکه‌ی عصبی خطی می‌تواند دینامیک پرنده را در فرم فضای حالت به خوبی شناسایی کند. در دینامیک شناسایی شده، اثرات نوبز داده‌های آزمون تضعیف شده و شبکه آن را به صورت حافظه‌دار دنبال نکرده است. نتایج ارزیابی مجدد کیفیت شناسایی (با استفاده از داده‌های آزمون پروازی ثانویه) نیز نشان می‌دهد که دینامیک شناسایی شده به کمک شبکه‌ی عصبی، به خوبی می‌تواند خروجی‌های سیستم را در سایر آزمون‌های پروازی دنبال کند. همچنین، مقایسه‌ی کیفیت شناسایی به کمک شبکه‌ی عصبی با شناسایی به روش SSEST نشان می‌دهد که استفاده از شبکه‌ی عصبی خطی برای شناسایی دینامیک پرنده، مناسب و قابل رقابت با سایر روش‌های شناسایی است، ضمن آن‌که پیاده‌سازی آن ساده و حجم محاسبات آن کم است.

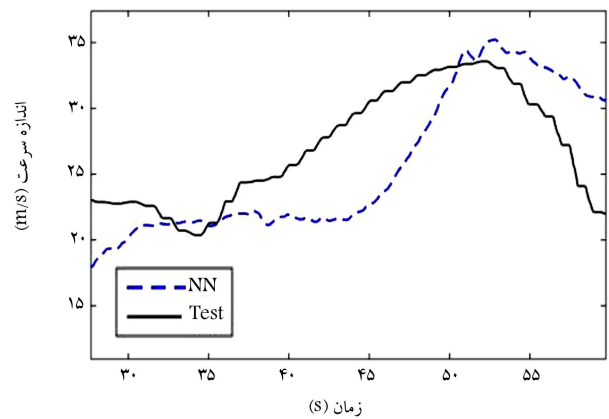
مدل دینامیک پرنده که در این پژوهش شناسایی شد، به صورت چندوردی - چندخروجی (و بدون تفکیک دینامیک طولی و عرضی) است. بنابراین، می‌توان اثرات و شدت کوپلینگ بین حالت‌ها و ورودی‌های دینامیک پرنده را به وسیله‌ی این مدل بررسی کرد. برای مثال، با بررسی درایه‌های ماتریس  $G$ ، تأثیر نرخ پیچ بر نرخ رول قابل مشاهده است. این کوپلینگ با توجه به چرخش ملخ (و اجزای دوار موتور)، قابل پیش‌بینی بود. از مدل شناسایی شده می‌توان برای بررسی پایداری، تعیین مودهای دینامیکی، طراحی کنترل‌کننده و شبیه‌سازی پرنده استفاده کرد. همچنین، از شبکه‌ی عصبی خطی برای شناسایی دینامیک پرنده، به صورت برخط نیز می‌توان استفاده کرد. در این حالت، در شرایطی که دینامیک پرنده (با شرایط محیطی) در حال تغییر باشد، شبکه‌ی عصبی خطی می‌تواند به خوبی این تغییرات را دنبال و مدل واقعی سیستم را شناسایی کند. از این مدل می‌توان برای طراحی کنترل‌کننده‌ی تطبیقی و تشخیص عیب یا افت عملکرد زیرسیستم‌های پرنده استفاده کرد.

## ۷. تشکر و قدردانی

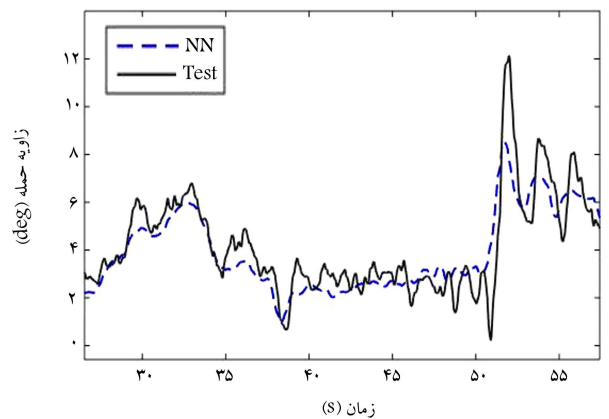
از دفتر فناوری هدایت و کنترل دانشگاه صنعتی شریف که داده‌های آزمون پروازی پرنده وایو را برای انجام این پژوهش در اختیار نگارندگان قرار دادند، تشکر و قدردانی می‌شود.

## پانویس‌ها

1. coupling
2. state-space estimation
3. radial basis network
4. steepest descent
5. Wayo
6. polyhedral
7. angle of attack
8. sideslip angle
9. net input
10. numerical algorithm for subspace identification



شکل ۱۸. سرعت پرنده (شامل خروجی آزمون پروازی دوم و شبکه‌ی خطی).



شکل ۱۹. زاویه‌ی حمله پرنده (شامل خروجی آزمون پروازی دوم و شبکه‌ی خطی).

## ۶. نتیجه‌گیری

در این پژوهش از یک شبکه‌ی عصبی خطی برای شناسایی دینامیک پرنده بدون سرنشین وایو استفاده شد. شناسایی دینامیک پرنده (با استفاده از داده‌های آزمون پروازی) به صورت چندوردی - چندخروجی و در دو مدل انجام شد. در مدل اول، حالت‌های پرنده شامل سرعت‌های زاویه‌ی، زوایای رول و پیچ و شتاب‌های

۱۱. یادآور می‌شود که در روش SSEST، مقادیر پیش‌فرض الگوریتم در نرم‌افزار متلب لحاظ شده، و تغییری در آن اعمال نشده است.

12. root mean square (RMS)
13. epoch

## منابع (References)

1. Tischler, M.B. and Rempfle, R.K. "Aircraft and rotorcraft system identification", AIAA education series (2006).

2. Klein, V. and Morelli, E.A. "Aircraft system identification: theory and practice", Reston, Va, USA: American Institute of Aeronautics and Astronautics (2006 Aug).
3. Billings, S.A. *Nonlinear system identification: NARMAX methods in the time, frequency, and spatio-temporal domains*, John Wiley & Sons, pp.1-3 (2013).
4. Narendra, K.S. and Parthasarathy, K. "Identification and control of dynamical systems using neural networks", *IEEE Transactions on Neural Networks*, **1**(1), pp. 4-27 (1990 Mar).
5. Chen, S., Billings, S.A. and Grant, P.M. "Non-linear system identification using neural networks", *International journal of control*, **1,51**(6), pp. 1191-214 (1990 Jun).
6. Kosmatopoulos, E.B., Polycarpou, M.M., Christodoulou, M.A. and et al. "High-order neural network structures for identification of dynamical systems", *IEEE Transactions on Neural Networks*, **6**(2), pp. 422-31 (1995 Mar).
7. Lalot, S. and Lecoeuche, S. "Online identification of heat dissipaters using artificial neural networks", *Journal of Mechanical Engineering*, pp.411-416 (2001).
8. McMillen, R.L., Steck, J.E. and Rokhsaz, K. "Application of an artificial neural network as a flight test data estimator", *Journal of aircraft*, **32**(5), pp. 1088-94 (1995 Sep).
9. Kumar, M.V., Omkar, S.N., Ganguli, R. and et al. "Identification of helicopter dynamics using recurrent neural networks and flight data", *Journal of the American Helicopter Society*, **1,51**(2), pp. 164-74 (2006).
10. Samal, M.K., Anavatti, S. and Garratt, M. "Neural network based system identification for autonomous flight of an eagle helicopter", *IFAC Proceedings Volumes*, **31,41**(2), pp. 7421-6 (2008 Dec).
11. Kermanshahi, F. "Neural Network Approach to RPH Dynamic Modeling", MSc Thesis, Amirkabir University of Technology (2007).
12. Mortazavi, M.R. and Mortazavi, M. "Identification of aircraft dynamic model using artificial neural networks", *Aerospace Knowledge and Technology Journal*, **1,2**, pp. 15-23 (2013).
13. Radmanesh, A.R., Ayati, S.R. and Nemati, J. "Nonlinear system identification of a turboprop airplane using neural networks", ICAS 2015, February 3-4, Isfahan, Iran. COI: ICADI02\_038.
14. Saghafi, F. and Nikoosokhan, M. "Nonlinear identification of aircraft dynamical system based on NNARX neural network", *The 13th Annual International Conference on Mechanical Engineering*, Isfahan, Iran (Feb 2006).
15. Roudbari, A. and Saghafi, F. "Generalization of ANN-based aircraft dynamics identification techniques into the entire flight envelope", *IEEE Transactions on Aerospace and Electronic Systems*, **52**(4), pp. 1866-80 (2016 Aug).
16. Kirkpatrick, K. May, J. and Valasek, J. "Aircraft system identification using artificial neural networks", In51st AIAA Aerospace Sciences Meeting Including the New Horizons Forum and Aerospace Exposition, p. 878 (2013 Jan 9)
17. Harris, J., Arthurs, F., Henrickson, J.V. and et al. "Aircraft system identification using artificial neural networks with flight test data", *Unmanned Aircraft Systems (ICUAS), International Conference on 2016 Jun 7*, pp. 679-688 IEEE (2016).
18. Robert, F. Stengel., *Flight Dynamics*, Princeton, NJ: Princeton University Press, pp. 685-690, ISBN:9780691114071 (2004).
19. Sharif University of technology, Guidance and Control Research Center; <http://gcrs.sharif.ir/>, Tel: 021 66166316
20. Hagan, Martin, T. and et al., *Neural Network Design*, 2nd edition, Martin Hagan (2014).
21. Lennart, Ljung. *System Identification Toolbox: User's Guide*, MathWorks, Inc, Revision 26, Revised for version 9.0 (2014).
22. Ljung, L., *System Identification: Theory For the User*, Second Edition, Upper Saddle River, N.J: Prentice Hall (1999).
23. Zipfel. and Peter, H., *Modeling and simulation of aerospace vehicle dynamics*, Amer Inst of Aeronautics & Astronautics, Inc (2007).