

## پیش بینی عملکرد آیرودینامیکی بال مثلثی غیر باریک با استفاده از شبکه عصبی

محمد حسین طالبی<sup>۱\*</sup>، علیرضا موحدی<sup>۱</sup>، سعید فتحی<sup>۲</sup>، میلاد ذبیحی نژاد<sup>۱</sup>، سعید قدیری خواه<sup>۱</sup>

۱- دانشکده فنی و مهندسی، گروه مهندسی مکانیک، دانشگاه علم و هنر، یزد، ۸۹۱۶۷۱۳۳۳۵

۲- پژوهشکده مکانیک، پژوهشگاه فضایی ایران، شیراز، ۷۱۵۵۸-۶۴۱۸۵

\*[talebi@sau.ac.ir](mailto:talebi@sau.ac.ir)

### چکیده

در مطالعه حاضر به پیش بینی اثر زمین بر مشخصات و عملکرد آیرودینامیکی بال مثلثی غیرباریک با استفاده از شبکه عصبی مصنوعی پرداخته می شود. پس از استخراج داده های مورد نیاز از مقاله مبنا، توانایی تابع اساسی شعاعی بر پیش بینی داده ها با استفاده از پارامترهای آماری مختلف بررسی شده است. با استفاده از داده های پیش بینی شده، نمودارهای تغییرات ضرایب لیفت نسبت به فاصله بال از زمین و زاویه حمله باز رسم شده است. در بخش بعد، به منظور مشخص کردن کارایی الگوریتم شبکه عصبی مطالعه حاضر، دقت الگوریتم در ورودی های مختلف آموزش و داده های تست متنوع شبکه عصبی تخمین زده شده است. نهایتاً از الگوریتم تابع اساسی شعاعی برای پیش بینی ضریب درگ استفاده شده است. ضریب رگرسیون یک و ضریب تعیین ۰.۹۹۸ برای پیش بینی ضریب لیفت ارائه شده است و مقدار خطا کم تر از ۴ درصد برای محاسبه ضریب درگ با استفاده از شبکه عصبی پیش بینی شده است.

کلید واژه: بال مثلثی، شبکه عصبی، تابع اساسی شعاعی، ضریب لیفت، ضریب درگ

### Prediction of Aerodynamic Performance of a Non-Slender Delta Wing Using Neural Network Abstract

The effects of non dimensional distance between ground and trailing edge and angle of attack on aerodynamic forces of non-slender delta wing are analysed using artificial neural network in the present study. The capability of radial basis function algorithm in prediction of data was estimated using statistical parameters, after extraction data from base article. The graph of lift coefficients into distance between ground and trailing edge and angle of attack were redrawn by predicted data. Then, in order to the determination of algorithm efficiency, precision of test data prediction was determined in different type of train data. Finally, prediction of drag coefficients was carried out using radial basis function of present study.

**Keywords:** Delta Wing, Neural Network, Radial Basis Function, Lift Coefficient, Drag Coefficient

### مقدمه

بال های دارای زاویه تمایل در کاربردهای مهندسی فراگیر هستند و دارای کاربری مشابهی برای شناگران و پرواز کننده ها هستند. به خصوص، بال های مثلثی محدوده وسیعی از کاربرد را چه در حین مشخصات مانور در سرعت کم و چه در هنگام رسیدن به سرعت نزدیک صوت، دارند. هواپیماهای جت مدرن برای دسترسی عموم در نظر گرفته

شده‌اند و تلاش شده است از لحاظ شکل هندسی دارای صرفه اقتصادی باشد. جت های مدرن در سرعت‌های حدود صوت پرواز می‌نمایند و به سمت راندمان بالاتر در عین هزینه پایین تر متمایل شده‌اند. ملاحظات اقتصادی و محیط زیستی برای افزایش راندمان سوختی منجر به تلاش‌های از سوی ناسا و بویینگ برای ساخت هواپیما با بدنه ترکیب شده با بال شده است که راندمان سوخت و نسبت لیفت به درگ را افزایش می‌دهد. اخیراً وسایل نقلیه هوایی بدون سرنشین توسعه یافته با کمترین سطوح کنترل طراحی شده‌اند تا راندمان بالاتر رفته و سطح مقطع رادار کاهش یابد [۱، ۲]. هواپیما با بال مثلثی مشخصات لازم را برای تاخیر در واگرایی درگ و مینیمم کردن درگ موجی را به منظور پرواز در سرعت‌های حدود صوت و مافوق صوت فراهم می‌سازد. جهت گیری پیرامون مطالعه در این زمینه از زمان جنگ جهانی دوم شدت گرفت [۳، ۴]. این مدل از بال‌ها به دلیل زاویه متمایل خود دسته بندی می‌شوند. بال‌ها با زاویه تمایل بزرگ‌تر از ۵۵ درجه به صورت باریک شناخت و طراحی می‌شوند در صورتی که بال با زاویه پایین تر به صورت غیرباریک شناخته می‌شود. تغییرات ساختار گردابه نسبت به زاویه حمله برای بال مثلثی غیر باریک منحصر به فرد است. در زاویه‌های تلاقی پایین، ساختار ابتدایی گردابه نزدیک به سطح بال شکل می‌گیرد. این قضیه باعث تشکیل ساختار گردابه‌ای دوتایی به دلیل تداخلات با لایه مرزی می‌شود. شواهد برای تایید این ساختار گردابه‌ای دوتایی را می‌توان در مطالعه گوردنیر و ویزبال [۵] و تیلور و همکاران [۶] که مدارکی تجربی پیرامون آن ارائه کردند، یافت.

تقریباً در تمامی مطالعات و پژوهش‌ها تاکید شده است که مشخص ساختن ناحیه ایجاد شکاف گردابه، برای بال مثلثی غیر باریک بسیار مشکل است. در زاویه حمله ۴۵ درجه، کوهلمن و ونتر [۷] نتوانستند ناحیه شکاف گردابه را در فرآیند تشکیل گردابه مشخص نمایند. آن‌ها در مستندات خود اشاره نمودند که برای اکثر هندسه‌های بال مثلثی غیر باریک، شکاف گردابه‌ای در ناحیه‌ای نزدیک به رأس بال اتفاق می‌افتد. بال‌های متمایل شده تقریباً در تمامی هواپیماهای جت مدرن رایج است تا بتوان راندمان را در سرعت‌های حدود صوت بهبود بخشید. به خصوص برای زاویه‌های تمایل غیر باریک و سطوح مقطع ضخامت دار ویژگی‌های رایج بدنه‌های ترکیب شده و وسایل هوایی جنگی بدون سرنشین هستند [۸، ۹]. یالا و همکاران [۱۰] ساختار جریان را به صورت کیفی اطراف بال لامبا نشان دادند و همچنین با استفاده از سرعت سنج تصویری ذرات، داده‌های لحظه‌ای جریان بال غیرباریک لامبا استخراج کردند تا هندسه متوسط زمانی را پیش‌بینی کنند و جزئیات پیرامون پدیده‌های مهم مانند تشکیل گردابه‌های لبه حمله و شکاف گردابه‌ای در صفحات عمودی و عرضی مشخص شود.

### شبکه عصبی

روش‌های شبکه عصبی امیدواری طراحان را به دلیل سرعت و هوش بالا به شدت افزایش داده است. مثال‌هایی از استفاده شبکه عصبی در طراحی بال و ایرفویل‌ها وجود دارد. پژوهش‌ها مدل شبکه عصبی را به عنوان ابزاری هندسی برای تعیین آیرودینامیک اشکال معرفی نمودند [۱۱]. در سال‌های اخیر، شبکه‌های عصبی مصنوعی وارد فرایند طراحی معکوس ایرفویل‌ها شده‌اند جایی که شبکه‌های عصبی مصنوعی نقش مهمی را در محاسبات مدل از پیش ایجاد شده ایفا می‌نمایند. از دهه ۱۹۹۰ با افزایش داده‌های پایه و روش‌های هوش مصنوعی، طراحی‌های آیرودینامیک جت‌ها به سرعت رو به جلو رفته است [۱۲]. تولید کنندگان هواپیماها به داده‌های پایه‌ای که در تجربیات طراحی گذشته و یا داده‌های آزمایشگاهی وجود دارد، دسترسی دارند. روش‌های بهینه سازی شامل بهینه سازی تئوری کنترل [۱۳، ۱۴]، الگوریتم ژنتیک [۱۵]، روش بهینه سازی گروهی ذرات [۱۵] و شبکه‌های عصبی مصنوعی است [۱۶]. شبکه عصبی شهرت خود را برای توانایی در ایجاد ارتباط غیرخطی بین ورودی و خروجی‌ها مانند ارتباط بین خصوصیات شکل هندسی و خصوصیات آیرودینامیکی مانند ضریب لیفت دارد. همان طور که مشخص گردید، روش‌های طراحی با شبکه عصبی مقدار محاسبات و هزینه زمانی را کاهش می‌دهد. اما


همچنان ابهاماتی به دلیل قابلیت اعتماد در طراحی به دلیل توضیحات ساختاری مدل شبکه عصبی وجود دارد [۱۷، ۱۸].

جریان غیر خطی می‌تواند اثرات نامطلوب بسیاری را مانند کنترل ناپایداری و شکست ساختار ایجاد نماید [۱۹]. اخیراً مطالعات بسیاری در زمینه کاهش این اثرات صورت گرفته است. روش‌های معمول مانند آزمایش‌های تونل باد و دینامیک سیالات محاسباتی که به صورت گسترده از آن‌ها استفاده شده است از لحاظ اقتصادی و مصرف توان به صرفه نیستند [۲۰]. شبکه‌های عصبی جانشین مناسبی برای آنالیز جریان آیرودینامیکی هستند چرا که به مدل‌های فیزیکی و تئوری‌های آیرودینامیکی وابسته نیستند. از این‌رو به دانش‌های آیرودینامیکی وابسته نیستند. از آن مهم‌تر شبکه‌های عصبی می‌توانند برای حل مسائل غیر خطی استفاده شوند [۲۱]. در زمان‌های اخیر، تنوع شبکه‌های عصبی که در مسائل آیرودینامیکی از آن‌ها استفاده می‌شوند شامل شبکه عصبی کانولوشن، ماشین برداری حمایتی و پرسپترون چندلایه هستند. زیلانگ و همکاران [۲۲] از شبکه‌های عصبی برای پیش‌بینی ضرایب آیرودینامیکی هواپیما با استفاده از فواصل طولی در هندسه ایرفویل استفاده کردند. عبدالرحمان و همکاران [۲۲] از روش پرسپترون چندلایه برای پیش‌بینی ضریب فشار بال دلتا استفاده کردند مدل مورد استفاده آن‌ها بال مثلی غیر باریک با لبه‌های تیز است. داده‌های ورودی شبکه عصبی، زاویه حمله و نقاط قرارگیری لوله فشار و داده‌های خروجی ضریب فشار است. نتایج مطابقت خوبی با بادقت‌ترین شبیه سازی‌ها را نشان می‌دهد.

در مطالعه حاضر به بررسی پیش‌بینی تغییرات ضریب لیفت و درگ بال مثلی با استفاده از شبکه عصبی مصنوعی پرداخته شده است. اثرات فاصله بال تا زمین و زاویه حمله بر تغییرات ضرایب آیرودینامیک بال مثلی به صورت الگوریتم غیرخطی شبکه عصبی تخمین زده شده است. علی‌رغم اینکه مطالعات بسیاری در زمینه شبیه سازی عددی و تجربی بال مثلی صورت گرفته است، مطالعات اندکی پیرامون پیش‌بینی ضرایب لیفت و درگ صورت گرفته است. نوآوری مطالعه حاضر از دو منظر قابل بررسی است، پیش‌بینی ضریب لیفت و درگ بر اساس تغییرات زاویه حمله و اثر فاصله بال تا زمین با استفاده از تابع شعاعی از توابع پیش‌رو شبکه عصبی، تا به حال انجام نشده است. همچنین به لحاظ زمانی و محاسباتی و هزینه آزمایش‌های تجربی نسبت به روش‌های شبیه سازی عددی و تجربی به صرفه‌تر است و دقت بالایی الگوریتم شبکه عصبی مطالعه حاضر برای پیش‌بینی ضریب لیفت و درگ دارد که در بخش نتایج ارائه شده است.

### ساختار شبکه عصبی


شبکه عصبی مصنوعی یک مدل محاسباتی از یادگیری ماشینی و همچنین آشکارسازی الگو است که از سیستم عصبی مرکزی مغز حیوانات الهام گرفته است. شبکه‌های عصبی دارای کاربردهای مختلفی در زمینه علوم مرتبط با مهندسی مکانیک و هوافضا هستند [۲۳-۲۶]. شکل ۱ مدل اصلی نورون مصنوعی را نشان می‌دهد. جزییات بیش‌تر پیرامون نحوه کارکرد الگوریتم‌های شبکه عصبی در منابع مختلف ارائه شده است [34,43].



## شکل ۱. شماتیک اساس شبکه عصبی

### تابع اساسی شعاعی

از نظر مدل سازی ریاضی، شبکه تابع اساسی شعاعی (شکل ۲) یک شبکه عصبی مصنوعی است که از تابع اساسی شعاعی برای فعال سازی استفاده می کند. جزییات نوع الگوریتم استفاده شده در مطالعه حاضر مشابه با الگوریتم تابع اساسی شعاعی استفاده در مطالعه فتحی و صادقی [۲۷] می باشد.



## شکل ۲. ساختار شبکه تابع اساسی شعاعی

لایه ورودی شامل  $m$  نورون است که با استفاده از بردار  $x_m = (a_{m1}, a_{m2}, \dots, a_{mn})$  ارائه می شود که در آن  $n$  تعداد نمونه ها است. بردار خروجی با عنوان  $y$  مشخص می شود. عبارت برای بردار خروجی  $n$  امین نورون در لایه خروجی به صورت رابطه (۱) محاسبه می شود. به منظور گسترش محاسبات، تعداد نورون لایه مخفی معمولاً بزرگ تر از لایه ورودی است. در این مطالعه تابع اساسی شعاعی به صورت مستقیم با استفاده از نرم افزار متلب به کار برده شده است که نیاز به انجام بسیاری از محاسبات را حذف می کند. بردار ورودی  $H_{j, in}$  و بردار خروجی  $H_{j, out}$ ،  $j$  امین نورون در لایه مخفی با استفاده از روابط (۲) و (۳) صورت می گیرد.

که در آن  $C_{mj}$  مرکز  $j$  امین نورون منطبق بر  $x_m$  است و  $C_{mj} = (a_{mj1}, a_{mj2}, \dots, a_{mjn})$  و  $\delta$  نرخ گسترش است [43].

$$y_i = \left[ \sum (W_{ij} \times H_{j, out}) \right] \quad (1)$$

$$H_{j, in} = \|x_m - C_{mj}\| \quad (2)$$

$$H_{j, out} = \exp\left(-\frac{H_{j, in}^2}{\delta^2}\right) \quad (3)$$

مدل تابع اساسی شعاعی با استفاده از دستور شبکه  $net = newrb(I, T, S)$  در نرم افزار متلب اجرا شده است که در آن  $I$  مقادیر ورودی،  $T$  مقادیر هدف و ضریب گسترش را ارائه می کند. مقدار اولیه ضریب گسترش بین صفر و یک تنظیم می شود.

### روابط آماری

راندمنان شبکه عصبی باید مورد ارزیابی قرار گیرد. چندین پارامتر آماری بدین منظور مورد استفاده قرار

گرفته است. ریشه خطای میانگین مربعات (RMSE) (عدم قطعیت)<sup>۱</sup>، خطای اندازه گیری میانگین (MAE)<sup>۲</sup>، ضریب تعیین (CE)<sup>۳</sup> از این دسته از پارامترها هستند که به فرم روابط (۴) تا (۶) محاسبه می گردند [۲۷].

$$RMSE = \left[ \frac{1}{N} \sum_{i=1}^N \left( \hat{u}_i - u_i \right)^2 \right]^{1/2} \quad (4)$$

$$MAE = \frac{1}{N} \sum_{i=1}^N \left| \hat{u}_i - u_i \right| \quad (5)$$

$$CE = 1 - \frac{\sum_{i=1}^N \left( \hat{u}_i - u_i \right)^2}{\sum_{k=1}^N \left( \hat{u}_i - \bar{\hat{u}} \right)^2} \quad (6)$$

$u_i$  و  $\hat{u}_i$  و  $\bar{\hat{u}}$  به ترتیب داده های واقعی و پیش بینی و میانگین شده هستند. هرچه قدر مقدار عدم قطعیت، میانگین خطای اندازه گیری و خطای استاندارد پارامتر مورد نظر کم تر باشد شبکه عصبی طراحی شده کارایی بهتری را برای پیش بینی داده های تست دارد. برای یک الگوریتم شبکه عصبی مناسب، ضریب تعیین نزدیک به یک است و محدوده ای بین صفر تا یک را دارا است. اگر این پارامتر یک باشد همبستگی خوبی بین داده های نمونه اندازه گیری شده و پیش بینی شده وجود دارد. درواقع اگر ضریب تعیین صفر باشد معادله رگرسیون نمی تواند در پیش بینی مقادیر مورد نظر کمکی کند.

شبکه عصبی مصنوعی می تواند الگوریتم های پیچیده غیرخطی را پیش بینی نماید، همچنین درون یابی و همزمان برون یابی داده ها را توسعه دهد. علی رغم مطالعات بی شمار در زمینه بال های مثلثی پژوهش های کمی پیرامون پیش بینی تغییرات ضرایب آیرودینامیکی لیفت و درگ صورت گرفته است. همچنین از تابعی سریع و با دقت برای پیش بینی داده ها استفاده شده است. تأثیرات فاصله عمودی زمین تا لبه فرار و زاویه حمله بر تغییرات ضریب لیفت و ضریب درگ جریان با استفاده از تابع اساسی شعاعی که یکی از توابع بادقت شبکه عصبی است پیش بینی می شود. در نهایت از الگوریتم تابع اساسی شعاعی برای پیش بینی ضریب درگ نسبت به تغییرات فاصله بدون بعد زمین تا بال و زاویه حمله استفاده شده است و مشخص است تابع اساسی شعاعی می تواند به خوبی تغییرات بال غیر باریک مثلثی را پیش بینی نماید.

## نتایج


سahین و همکاران [۲۸] اثر زمین بر بال مثلثی با زاویه تمایل ۴۰ درجه را با استفاده از سرعت سنج تصویری ذرات، سیستم اندازه گیری نیروی آیرودینامیکی و روش آشکارسازی جریان رنگی بررسی کردند. شماتیک بال مثلثی مطالعه ساهین و همکاران [۲۸] که شامل جهت محورهای مختصات، زاویه حمله  $\alpha$  و فاصله بال مثلثی تا زمین  $h$  در شکل ۳ الف نشان داده شده است. همچنین تغییرات ضرایب لیفت و درگ نسبت به فاصله بدون بعد بال مثلثی نسبت به زمین در زاویه حمله های مختلف که مبنای استخراج داده های مطالعه حاضر هستند، در شکل ۳ ب و پ ارائه شده است. فاصله بال تا زمین با استفاده از وتر بال بدون بعد شده است. آزمایش را در زاویه های حمله مختلف ۲ تا ۲۹ درجه با اختلاف زاویه ۳ درجه محاسبه شده است، سرعت بالادست ۱۶,۵۷ متر بر ثانیه و نسبت فاصله عمود زمین تا لبه فرار بال به صورت ۰,۱، ۰,۲۵، ۰,۴، ۰,۵۵ و ۰,۷  $h/c$  تغییر پیدا می کند. در مطالعه حاضر، داده های

3. Root mean square error (uncertainty)


4. Mean absolute error

۱. Coefficient efficiency


اندازه‌گیری شده پژوهش ساهین و همکاران [۲۸] استخراج شده و به پیش‌بینی ضرایب لیفت و درگ در زاویه‌های حمله مختلف برای فواصل مختلف زمین تا لبه فرار پرداخته شده است با استفاده از شبکه عصبی پرداخته شده است. از تابع اساسی شعاعی به عنوان یکی از جدیدترین و کارآمدترین توابع شبکه عصبی یاد می‌شود. در دو بخش به تخمین عددی داده‌های شبکه عصبی پرداخته شده است. در هر دو حالت زاویه



(الف)



(پ)



(ب)

شکل ۳. مشخصات بال مثلی و نتایج برگرفته شده از مطالعه ساهین و همکاران: [۲۸] (الف) شماتیک هندسی بال مثلی و پارامترهای هندسی مسأله، (ب) تغییرات ضریب لیفت نسبت به زاویه‌های حمله و فاصله بدون بعد بال مثلی تا زمین، (پ) تغییرات ضریب درگ نسبت به زاویه‌های حمله و فاصله مختلف بدون بعد بال مثلی تا زمین

حمله و فاصله عمودی زمین تا لبه فرار به عنوان ورودی تابع شبکه عصبی انتخاب شده است. در حالت اول خروجی ضریب لیفت و در حالت دوم خروجی ضریب درگ می‌باشد. پس از تغییرات پارامترهای مؤثر در شبکه عصبی، بهترین الگوریتم برای محاسبه ضرایب لیفت و درگ انتخاب شده است. نمودار و جداول تغییرات داده‌ها و محاسبه خطاهای وارد بر آن‌ها ارائه شده‌اند و در نهایت الگوهای موجود در مطالعه ساهین و همکاران [۲۸] باز رسم شده‌اند.

#### اعتبار سنجی نتایج پیش‌بینی ضریب لیفت

به منظور بررسی میزان موفقیت و کارایی مدل شبکه عصبی مطالعه حاضر، نتایج به دست آمده با استفاده از الگوریتم تابع شعاعی در دو حالت آموزش و تست با نتایج مطالعه ساهین و همکاران [۲۹] مقایسه شده است. ساهین و همکاران [۲۹] از الگوریتم شبکه عصبی لونبرگ مارکوردات (LM) برای پیش‌بینی نتایج تجربی مطالعه خود استفاده کردند. در جدول ۱ پارامترهای آماری مختلف، عملکرد تابع اساسی شعاعی مطالعه حاضر را با نتایج

مطالعه ساهین و همکاران [۲۹] مقایسه کردند. ضریب رگرسیون نمودارهای توزیع رگرسیون خطی ( $R^2$ ) و شیب خط برازش داده شده از داده‌های آموزش در تمامی حالت‌های فاصله بدون بعد بال نسبت به زمین برای الگوریتم تابع اساسی شعاعی مطالعه حاضر برابر با یک محاسبه شده است در صورتی که این مقادیر برای مطالعه ساهین و همکاران [۲۹] کمتر از یک گزارش شده است. در بخش تحلیل داده‌های تست، مقدار خطای مطلق میانگین داده‌های پیش بینی شده با استفاده از تابع اساسی شعاعی بسیار کمتر از مقدار مشابه ارائه شده توسط مطالعه ساهین و همکاران [۲۹] می‌باشد. بنابراین می‌توان بیان نمود مطالعه حاضر توانسته است الگوریتم پیش بینی مقادیر ضریب لیفت بال مثلثی غیر باریک نسبت به فاصله بدون بعد از زمین و زاویه حمله مختلف را بهبود ببخشد و عملکرد دقیق‌تری را ارائه نماید.

### پیش بینی ضریب لیفت

داده‌های استخراج شده ضریب لیفت از مطالعه ساهین و همکاران [۲۸] برای زاویه‌های حمله ۲ تا ۲۹ و فاصله عمودی زمین تا لبه فرار بال مثلثی ۰,۱، ۰,۲۵، ۰,۴، ۰,۵۵ و ۰,۷  $h/c$  است. تعداد کل داده‌های اخذ شده ۴۳۲ نقطه است که ۲۰ درصد آن معادل ۸۶ عدد به عنوان داده‌های تست به صورت تصادفی انتخاب شده است و مابقی آن برای داده‌های آموزش می‌باشد. پس از انتخاب پارامترهای مختلف شبکه عصبی برای کار بر روی داده‌های آموزش، مناسب‌ترین الگوریتم انتخاب شده است. نمودار توزیع رگرسیون خطی حاصل از آموزش داده‌های آموزش در شکل ۴ الف نشان داده شده است. شیب خط رگرسیون برابر یک و عرض از مبدا خط نزدیک صفر است که نشان


### جدول ۱. مقایسه آماری نتایج الگوریتم تابع اساسی شعاعی و مطالعه ساهین و همکاران [۲۹] در پیش

#### بینی ضریب لیفت بال مثلثی غیر باریک


| Function                             | $h/c$ | $R^2$ | s     | MAE                   |
|--------------------------------------|-------|-------|-------|-----------------------|
| RBF                                  | ۰,۷   | 1     | 1     | $1,12 \times 10^{-5}$ |
|                                      | ۰,۵۵  | 1     | 1     | $0,000104$            |
|                                      | ۰,۴   | 1     | 1     | $8,57 \times 10^{-5}$ |
|                                      | ۰,۲۵  | 1     | 1     | $3,19 \times 10^{-5}$ |
|                                      | ۰,۱   | 1     | 1     | $6,54 \times 10^{-5}$ |
| LM<br>مطالعه ساهین و<br>همکاران [۲۹] | ۰,۷   | ۰,۹۹۹ | ۰,۹۹۵ | ۰,۰۰۵۲                |
|                                      | ۰,۵۵  | ۰,۹۹۹ | ۰,۹۹۱ | ۰,۰۰۶۵                |
|                                      | ۰,۴   | ۰,۹۹۸ | ۰,۹۸  | ۰,۰۰۸۶                |
|                                      | ۰,۲۵  | ۰,۹۹۸ | ۱,۰۱۸ | ۰,۰۰۸۳                |
|                                      | ۰,۱   | ۰,۹۹۸ | ۰,۹۷۹ | ۰,۰۱۲۳                |

از منطبق بودن مناسب خط برازش شده از داده‌های پیش بینی شده و خط برازش شده داده‌های واقعی دارد. همچنین ضریب رگرسیون حاصل از پیش بینی داده‌های آموزش در حالت کلی برابر یک به دست آمده است که نشان از توانایی شبکه عصبی در پیش بینی داده‌های آموزش در حالت کلی دارد. در تمامی نمودارها، نتایج به دست آمده توسط الگوریتم شبکه عصبی مطالعه حاضر با نماد داده‌های پیش بینی شده یا Predicted data و داده‌های مطالعه ساهین و همکاران [۲۸] که با استفاده از آزمایش تجربی به دست آمده است با نماد داده‌های واقعی و یا Real data نشان داده شده است. در شکل ۴ ب توزیع نقطه‌ای داده‌های آموزش برای ضرایب لیفت در حالت کلی نشان داده شده است که مشخص است که داده‌های آموزش پیش بینی شده از انطباق بسیار مناسبی با داده‌های واقعی برخوردار هستند. در نهایت برای داده‌های آموزش تغییرات درصد خطای مطلق در شکل ۴ پ نشان داده شده است. محدوده تغییرات درصد خطای مطلق برای پیش بینی داده‌های آموزش ضریب لیفت در حالت کلی در محدوده


± ۰,۶ تعیین شده است. پس از شناسایی الگوریتم مناسب در پیش بینی داده‌های آموزش به بررسی کارایی و اعتبارسنجی الگوریتم محاسبه شده در پیش‌بینی داده‌های تست ضریب لیفت پرداخته شده است. داده‌های تست به صورت تصادفی انتخاب شده‌اند. ضریب رگرسیون پیش‌بینی داده‌های تست (شکل ۴ ت) ۰,۹۹۹۵۳ و مقدار شیب خط برازش شده روی داده‌های تست پیش‌بینی شده ۰,۹۹ محاسبه شده است. بنابراین الگوریتم محاسبه شده توانایی مناسبی در پیش‌بینی داده‌های تست ضریب لیفت در حالت کلی دارد. توزیع نقطه‌ای داده‌های تست برای ضریب لیفت در شکل ۴ ث نشان داده شده است. مشخص است تابع اساسی شعاعی به خوبی توانسته است داده‌های تست را پیش‌بینی نماید و انطباق داده‌ها قابل قبول است. همچنین تغییرات درصد خطای مطلق برای داده‌های تست در محدوده ۴ تا ۲- درصد است (شکل ۴ ج) که توانایی بسیار مناسب شبکه عصبی مطالعه حاضر در تخمین و پیش‌بینی داده‌های تست در حالت کلی را نشان می‌دهد.




(ت)




(الف)




(ث)



(ب)



(ج)



(پ)




شکل ۴. نمودار پیش بینی ضریب لیفت در حالت کلی: (الف) توزیع رگرسیون خطی داده‌های آموزش، (ب) توزیع نقطه‌ای داده‌های واقعی و داده‌های پیش بینی شده آموزش، (پ) درصد خطای اندازه‌گیری پیش بینی داده‌های آموزش، (ت) توزیع رگرسیون خطی داده‌های تست، (ث) توزیع نقطه‌ای داده‌های واقعی و داده‌های پیش بینی شده تست، (ج) درصد خطای اندازه‌گیری پیش بینی داده‌های تست


در این بخش به بررسی اثر نوع انتخاب داده آموزش و داده تست بر عملکرد الگوریتم تابع اساسی شعاعی پرداخته شده است. بدین منظور در هر مرحله داده‌های تست مربوط به یک فاصله بدون بعد بال از زمین به عنوان داده تست انتخاب شده است و داده‌های سایر فواصل بال از زمین برای آموزش شبکه عصبی استفاده می‌شوند. نتایج مرتبط با درصد خطای اندازه‌گیری و بازرس نمودارهای تغییرات ضریب لیفت نسبت به زاویه حمله برای هر فاصله بدون بعد بال نسبت به زمین ارائه شده است.

برای ضریب لیفت در فاصله زمین تا لبه فرار  $h/c = 0.7$  تعداد داده‌های تست برابر ۸۳ عدد است. بنابراین داده‌های به دست آمده برای فاصله بدون بعد زمین تا لبه فرار ۰.۱، ۰.۲۵، ۰.۴، ۰.۵۵ و  $h/c =$  در زوایای حمله مختلف گزینش شدند که به عنوان داده آموزش معرفی شدند و برابر ۳۴۹ عدد است. پس از به دست آمدن مناسب‌ترین الگوی آموزشی، داده‌های ورودی و خروجی به شبکه عصبی داده شدند. پس از بررسی درصد خطای مطلق در شکل ۵ الف مشخص گردید این تغییرات بین ۲ تا ۶ درصد است. نمودار تغییرات ضریب لیفت نسبت به افزایش زاویه حمله برای  $h/c = 0.7$  با استفاده از داده‌های مطالعه ساهین و همکاران [۲۸] و داده‌های پیش بینی شده با استفاده از تابع اساسی شعاعی مطالعه حاضر در شکل ۵ ج بازرس شده‌اند که نشان از دقت بالای پیش بینی شبکه عصبی مطالعه حاضر دارد. در فاصله بدون بعد ۰.۵۵، تعداد داده‌های آموزش و تست به ترتیب برابر ۳۳۹ و ۹۳ است که بیش از ۲۰ درصد داده کل داده‌ها برای داده تست در نظر گرفته شده است که این خود یک چالش برای انتخاب شبکه عصبی مناسب است. داده‌های فاصله زمین تا لبه فرار مدل ۰.۱، ۰.۴، ۰.۷، ۰.۱ و  $h/c =$  به عنوان داده آموزش گزینش شده‌اند. محدوده تغییرات درصد خطای مطلق بین ۲ تا ۴- است (شکل ۵ ب). همچنین نمودار بازرس شده در شکل ۵ چ تغییرات ضریب لیفت برای فاصله ۰.۵۵، نشان از کارایی مناسب الگوریتم شبکه عصبی مطالعه حاضر دارد. در فاصله بدون بعد زمین تا لبه فرار ۰.۴، تعداد داده‌های تست و آموزش به ترتیب برابر ۸۵ و ۳۴۸ است. محدوده تغییرات درصد خطای مطلق برابر  $\pm 0.6$  درصد است که بسیار عالی می‌باشد (شکل ۵ پ) و متعاقباً نمودار بازرس شده داده‌های تست پیش بینی شده مطابقت دقیقی با داده‌های واقعی پیش بینی شده تست دارند (شکل ۵ ح). در فاصله بدون بعد ۰.۲۵، الگوریتم شبکه عصبی به پیش بینی ۳۴۸ و ۸۴ نقطه از نمودار ضریب لیفت برای حالت آموزش و تست پرداخته است. محدوده درصد خطای مطلق برای داده‌های تست (شکل ۵ ت) برای فاصله بدون بعد ۰.۲۵، برابر ۲- تا ۴ درصد تخمین زده شده است. بررسی نمودار بازرس شده در شکل ۵ خ ضریب لیفت بر حسب تغییرات زاویه حمله در فاصله بدون بعد زمین تا لبه فرار ۰.۲۵، مشخص گردید به جز در ناحیه پیک که کمی اختلاف دیده می‌شود در سایر موارد انطباق خوبی بین داده‌های تست پیش بینی شده و داده‌های تست واقعی مشاهده می‌گردد اما با توجه به نمودار درصد خطای مطلق این اختلاف بسیار کم می‌باشد و تابع اساسی شعاعی به خوبی توانسته است داده‌های تست را پیش‌بینی نماید. برای نزدیک‌ترین فاصله بدون بعد تست شده در مطالعه ساهین و همکاران [۲۸] الگوریتم شبکه عصبی مطالعه حاضر در دو بخش داده‌های آموزش و تست، آزموده شده است. همان‌طور که در شکل ۵ ث نتایج درصد تغییرات خطای مطلق برای داده‌های تست در فاصله بدون بعد ۰.۱، برابر صفر تا ۶- می‌باشد. مقدار پیک تغییرات ضریب لیفت برای داده‌های پیش بینی شده کمی کمتر از این مقدار برای داده‌های واقعی است اما الگوی بازرس شده و تغییرات درصد خطای مطلق نشان از دقت تابع اساسی شعاعی مطالعه حاضر


دارد (شکل ۵ د). بنابراین الگوریتم تابع اساسی شعاعی در تمامی حالت‌های انتخاب داده آموزش با دقت بسیار بالایی توانسته است ضریب لیفت را نسبت به فاصله عمودی تا زمین و زاویه حمله پیش بینی نماید.




(الف)




(ب)




(ج)




(د)




(ه)




(و)




(ز)



(ح)



(د)



(ث)

شکل ۵. نمودار تغییرات درصد خطای مطلق اندازه‌گیری ضریب لیفت بدون فاصله بدون بعد زمین تا بال مثلثی: (الف)  $h/c=0,7$ ، (ب)  $h/c=0,5$ ، (پ)  $h/c=0,4$ ، (ت)  $h/c=0,25$ ، (ث)  $h/c=0,1$ ؛ نمودار تغییرات ضریب لیفت نسبت به زاویه حمله بدون فاصله بدون بعد زمین تا بال مثلثی: (ج)  $h/c=0,7$ ، (چ)  $h/c=0,5$ ، (خ)  $h/c=0,4$ ، (ح)  $h/c=0,25$ ، (د)  $h/c=0,1$ ؛


به لحاظ آیرودینامیکی همین طور که در شکل ۵ ضرایب لیفت در نواحی نامحدود دارای مقادیر بیش‌تری نسبت به نقاط نزدیک به زمین می‌باشد. برای مثال ضریب لیفت در زاویه حمله ۱۷ درجه در حدود ۰,۶۸ است در حالی که این مقدار برای فواصل بدون بعد ۰,۴ و ۱ به ترتیب برابر ۰,۷۲ و ۰,۸۹ است. در زاویه حمله ۱۱ درجه، ضریب لیفت از مقدار ۰,۵۶ به ۰,۶۱ برای فاصله بدون بعد بال تا زمین ۰,۵۵ تا ۰,۲۵ کاهش پیدا می‌کند.

#### بررسی تغییرات ضریب درگ


در حالت دوم ورودی شبکه عصبی همان زاویه حمله و فاصله بدون بعد عمودی زمین تا لبه فرار بال مثلثی است اما خروجی شبکه عصبی تغییر ضریب درگ می‌باشد. بنابراین داده‌های اخذ شده از مطالعه ساهین و همکاران [۲۸] برای تغییرات زاویه حمله ۲ تا ۲۹ و فاصله بدون بعد ۰,۱، ۰,۲۵، ۰,۴، ۰,۵۵ و  $h/c=0,7$  که توسط اندازه طول وتر بال مثلثی بی بعد شده است به عنوان داده‌های مورد استفاده در شبکه عصبی استخراج شده‌اند. در حالت کلی تعداد داده‌ها ۴۱۹ عدد است که ۸۴ نقطه آن معادل ۲۰ درصد کل داده‌ها به عنوان ورودی شبکه عصبی در نظر گرفته شده است. در حالت کلی به دلیل خلاصه کردن بخش نتایج، نمودارهای پیش‌بینی داده‌های آموزش ارائه نشده است و نمودارهای توزیع نقطه‌ای و درصد خطای مطلق داده تست نشان داده شده است. درصد خطای مطلق (شکل ۶ الف) پیش‌بینی ضریب درگ برای داده‌های تست در حالت کلی بین ۳- تا ۴ درجه تغییر می‌کند که تایید کننده تطابق مناسب توزیع نقطه‌ای داده‌های تست در شکل ۶ چ است.

برای فاصله بدون بعد ۰,۷ تغییرات ضریب درگ در زاویه‌های حمله مختلف توسط ساهین و همکاران [۲۸] نشان داده شده است. در این بخش برای خلاصه سازی نتایج تنها نمودارهای درصد خطای مطلق و نمودار بازرس شده داده‌های تست ارائه شده است تا کارایی و اعتبارسنجی روش شبکه عصبی مطالعه حاضر مورد بررسی قرار گیرد. شکل ۶ ب محدوده تغییرات داده‌های اکثر داده‌های تست را بین  $\pm 2$  درصد خطای مطلق نشان می‌دهد. اما نمودار باز رسم شده تغییرات ضریب درگ نسبت به تغییرات زاویه حمله برای فاصله بدون بعد ۰,۴ در شکل ۶ ج مشخص کرده است که این تغییرات درصد خطای مطلق بسیار ناچیز بوده است و الگوی ترسیمی با استفاده از داده‌های تست پیش‌بینی شده با استفاده از تابع اساسی شعاعی استفاده شده در مطالعه حاضر انطباق مناسبی با داده‌های واقعی دارد. شکل ۶ پ تغییرات درصد خطای مطلق داده‌های تست پیش‌بینی شده برای فاصله بدون بعد


۰,۵۵ زمین تا لبه فرار بال را نشان می‌دهد در نتیجه داده‌های به دست آمده برای ۰,۱، ۰,۲۵، ۰,۴ و ۰,۷ که برابر ۳۴۵ نقطه هستند به عنوان داده‌های آموزش انتخاب شده‌اند و داده‌های اخذ شده برای فاصله بدون بعد ۰,۵۵ برای داده‌های تست جهت اعتبارسنجی روش مطالعه حاضر معرفی شدند. تغییرات درصد خطای مطلق پیش بینی ضریب درگ داده‌های تست بین ۴ تا ۳- درصد است که باعث شده است نمودار بازرسم شده با استفاده از داده‌های تست پیش بینی شده به خوبی بر الگوی رفتاری داده‌های واقعی در شکل ۶ خ منطبق شود. در مرحله بعدی ۳۳۷ نقطه به عنوان داده آموزش و ۸۲ داده برای اعتبارسنجی نتایج گزینش شدند که مرتبط با داده‌های دارای فاصله بدون بعد ۰,۴ است. شکل ۶ ت درصد تغییرات خطای مطلق برای پیش بینی داده‌های تست را اکثراً بین ۴ تا ۲- تخمین زده‌اند. همین امر باعث شده است در اکثر نقاط نمودار باز رسم شده با استفاده از داده‌های پیش بینی شده توسط تابع اساسی شعاعی به خوبی بر الگوی رفتاری داده‌های مطالعه ساهین و همکاران منطبق گردد شکل ۶ د. در آنالیز داده تست فاصله بدون بعد ۰,۲۵، داده‌های آموزش و داده‌های تست به ترتیب ۳۲۶ و ۹۶ نقطه استخراج شدند. در محدوده تغییرات درصد خطای مطلق برای بیش‌تر داده‌های تست برابر  $\pm 3$  درصد به دست آمده است (شکل ۶ ث) که موید انطباق الگوی رفتاری جریان داده‌های تست تخمین زده شده با استفاده از روش شبکه عصبی مطالعه حاضر و الگوی رفتاری داده‌های واقعی است (شکل ۶ ذ). در نهایت پیش بینی ضرایب درگ، داده‌های فاصله بدون بعد ۰,۱ که برابر ۸۸ نقطه هستند به عنوان داده تست کنار گذاشته شدند و داده‌های ۳۳۲ نقطه برای آموزش تابع اساسی شعاعی انتخاب شده است. پس از بررسی تغییرات درصد خطای مطلق در شکل ۶ ج مشخص شد این تغییرات برای داده‌های تست شبکه عصبی در بیش‌تر نقاط تحلیل ۶ تا ۲- درصد می باشند که برای این که مشخص شود این مقدار خطا چه مقدار در کارآیی شبکه عصبی اثر دارد نمودار تغییرات ضریب درگ بر حسب زاویه حمله در شکل ۶ ر رسم شده است و مشخص است که الگوی رفتاری بازرسم شده توسط داده‌های تست تطابق بسیار مناسبی با داده‌های آموزش دارند.




(ج)




(الف)




(ح)




(ب)




(ا)




(ب)




(د)




(ت)




(ذ)



(ث)



(ر)



(ج)

شکل ۶. (الف) تغییرات توزیع نقطه‌ای داده‌های تست ضریب درگ در حالت کلی، (چ) تغییرات درصد خطای مطلق اندازه‌گیری داده‌های تست در حالت کلی؛ نمودار تغییرات درصد خطای مطلق اندازه‌گیری

ضریب درگ برای فاصله بدون بعد زمین تا بال مثلثی: (ب)  $h/c = 0,7$ ، (پ)  $h/c = 0,5$ ، (ت)  $h/c = 0,4$ ، (ث)  $h/c = 0,25$ ، (ج)  $h/c = 0,1$ ؛ نمودار تغییرات ضریب درگ نسبت به زاویه حمله برای فاصله بدون بعد زمین تا بال مثلثی: (ح)  $h/c = 0,7$ ، (خ)  $h/c = 0,5$ ، (د)  $h/c = 0,4$ ، (ذ)  $h/c = 0,25$ ، (ر)  $h/c = 0,1$ ؛

در شکل ۶ مشخص است که اثرات ناشی از وجود زمین منجر به ایجاد ضرایب درگ بزرگتری می‌شود. همچنین همان طور که مشخص است، ضریب درگ همواره با افزایش فاصله بدون بعد بال مثلثی از زمین افزایش پیدا می‌کند. برای مثال ضریب درگ همواره برای فاصله بدون بعد ۰,۱ بیش‌تر از فاصله بدون بعد ۰,۴ در تمامی زوایای حمله است. افزایش ضرب درگ به دلیل وجود زمین را می‌توان به کاهش فشار بسیار بالا در سطح بال و جدایش سریع‌تر جریان و ریزش گردابه‌ها از لبه حمله نسبت داد.

### آنالیز آماری

جدول ۲ و جدول ۳ به ترتیب پارامترهای آماری کارآیی شبکه عصبی مطالعه حاضر در پیش بینی داده‌های آموزش و داده‌های تست ضریب لیفت را نشان می‌دهد. از آن جایی که در تمامی موارد ضریب تعیین نزدیک به یک و مقادیر MAE و RMSE نزدیک به صفر هستند شبکه عصبی بسیار عالی و دقیق داده‌ها را پیش بینی نموده است. در پیش بینی داده‌های تست برای فاصله بدون بعد ۰,۱ که ضریب تعیین کم‌تر از سایر موارد می‌باشد از آن جایی که دو پارامتر دیگر نزدیک به صفر هستند می‌توان نتیجه گرفت به طور کلی عملکرد شبکه عصبی مطالعه حاضر در پیش بینی ضریب لیفت با دقت قابل قبول عمل کرده است.

جدول ۲. پارامترهای آماری بررسی کارآیی شبکه عصبی در پیش بینی داده‌های آموزش ضریب لیفت نسبت به تغییرات فاصله بال تا زمین

| Function | Parameter | RMSE     | MAE         | CE       |
|----------|-----------|----------|-------------|----------|
| RBF      | Total     | ۰,۰۰۰۳۴۷ | $7,45 e-09$ | ۰,۹۹۹۹۹۷ |
|          | ۰,۷       | ۰,۰۰۰۴۱۵ | $2,41 e-08$ | ۰,۹۹۹۹۹۶ |
|          | ۰,۵۵      | ۰,۰۰۰۴۲۴ | $1,64 e-08$ | ۰,۹۹۹۹۹۶ |
|          | ۰,۴       | ۰,۰۰۰۴۴۱ | $6,19 e-08$ | ۰,۹۹۹۹۹۵ |
|          | ۰,۲۵      | ۰,۰۰۰۴۵۴ | $8,4 e-10$  | ۰,۹۹۹۹۹۵ |
|          | ۰,۱       | ۰,۰۰۰۴۱۳ | $2,11 e-08$ | ۰,۹۹۹۹۹۵ |

جدول ۳. پارامترهای آماری بررسی کارآیی شبکه عصبی در پیش بینی داده‌های تست ضریب لیفت نسبت به تغییرات فاصله بال تا زمین

| Function | Parameter | RMSE   | MAE         | CE    |
|----------|-----------|--------|-------------|-------|
| RBF      | Total     | ۰,۰۰۷  | $6,74 e-09$ | ۰,۹۹۸ |
|          | ۰,۷       | ۰,۰۲۶  | $1,12 e-05$ | ۰,۹۷۹ |
|          | ۰,۵۵      | ۰,۰۱۰۶ | ۰,۰۰۰۱۰۴    | ۰,۹۹۶ |
|          | ۰,۴       | ۰,۰۰۶۷ | $8,57 e-05$ | ۰,۹۹۸ |
|          | ۰,۲۵      | ۰,۰۱۲۷ | $3,19 e-05$ | ۰,۹۹۶ |
|          | ۰,۱       | ۰,۰۲۹۴ | $6,54 e-05$ | ۰,۹۷۸ |

پارامترهای آماری در بررسی کارایی شبکه عصبی مطالعه حاضر در پیش بینی ضریب درگ در جدول ۴ و جدول ۵ ارائه شده‌اند. از آنجایی که در تمامی حالت‌های بررسی شده مقدار CE نزدیک به یک و مقدار MAE و RMSE نزدیک به صفر هستند، می‌توان گفت تابع اساسی شعاعی مطالعه حاضر در پیش بینی داده‌های ضریب درگ با دقت بسیار بالایی کار کرده است.

جدول ۴. پارامترهای آماری بررسی کارایی شبکه عصبی در پیش بینی داده‌های آموزش ضریب درگ نسبت به تغییرات فاصله بال تا زمین

| Function | Parameter | RMSE     | MAE       | CE       |
|----------|-----------|----------|-----------|----------|
| RBF      | Total     | ۰,۰۰۰۲۲۲ | ۲,۱۶ e-۱۰ | ۰,۹۹۹۹۹۷ |
|          | ۰,۷       | ۰,۰۰۰۲۵۸ | ۱,۷۸ e-۰۹ | ۰,۹۹۹۹۹۷ |
|          | ۰,۵۵      | ۰,۰۰۰۲۶  | ۹,۶۴ e-۰۸ | ۰,۹۹۹۹۹۷ |
|          | ۰,۴       | ۰,۰۰۰۲۶۲ | ۵,۱ e-۱۰  | ۰,۹۹۹۹۹۷ |
|          | ۰,۲۵      | ۰,۰۰۰۲۳۸ | ۸,۷۴ e-۷  | ۰,۹۹۹۹۹۷ |
|          | ۰,۱       | ۰,۰۰۰۲۳۲ | ۷,۷۹ e-۱۰ | ۰,۹۹۹۹۹۷ |

جدول ۵. پارامترهای آماری بررسی کارایی شبکه عصبی در پیش بینی داده‌های تست ضریب درگ نسبت به تغییرات فاصله بال تا زمین

| Function | Parameter | RMSE   | MAE        | CE    |
|----------|-----------|--------|------------|-------|
| RBF      | Total     | ۰,۰۰۵  | ۳,۰۲ e-۰۵  | ۰,۹۹۹ |
|          | ۰,۷       | ۰,۰۰۳  | ۱,۶۵ e-۰۵  | ۰,۹۹۹ |
|          | ۰,۵۵      | ۰,۰۰۳  | ۱,۵۵ e-۰۵  | ۰,۹۹۹ |
|          | ۰,۴       | ۰,۰۰۵  | ۷,۵۵ e-۰۵  | ۰,۹۹۸ |
|          | ۰,۲۵      | ۰,۰۰۴۹ | ۱,۰۰۳ e-۰۶ | ۰,۹۹۸ |

## نتیجه گیری

اثر زمین بر ساختار جریان گردابه‌ای و عملکرد آیرودینامیکی بال مثلی غیر باریک در مطالعه حاضر پیش بینی شده است. زمین مقدار پیک گردابه‌های اولیه و ثانویه لبه حمله را کاهش می‌دهد و فاصله ناکافی با زمین می‌تواند بر نیروهای آیرودینامیکی و توسعه غیر کامل گردابه‌ها اثرگذار باشد. در پژوهش حاضر عملکرد شبکه عصبی در پیش بینی ضرایب آیرودینامیکی لیفت و درگ بررسی شده است. برای آنالیز داده‌های استخراج شده از تابع اساسی شعاعی برای بال مثلی پژوهش حاضر الگوسازی شد و مناسب‌ترین الگو در پیش بینی داده‌های آموزشی انتخاب گردید. فاصله زمین تا لبه فرار بال مثلی که با استفاده از وتر بال بدون بعد شده است و تغییرات زاویه حمله بال مثلی پارامترهایی هستند که در پیش بینی ضرایب آیرودینامیکی لیفت و درگ استفاده شده‌اند. نمودارهای رگرسیون خطی عبوری از داده‌های واقعی و پیش‌بینی شده، مقایسه توزیع نقطه‌ای داده‌های واقعی و پیش‌بینی شده و تغییرات درصد خطای مطلق، از جمله نتایجی هستند که برای داده‌های آموزش و تست پیش‌بینی شده استفاده شدند و دقت بالای شبه عصبی استفاده شده در مطالعه حاضر را نشان می‌دهند. مقدار ضریب تعیین برای داده‌های آموزش در محدوده یک و برای داده‌های تست در محدوده ۰.۹۹۸ به بالا تغییر می‌کند. در بررسی تمام حالت‌های شبکه عصبی مطالعه حاضر، مشاهده کردید که تغییرات رگرسیون خطی، درصد خطای مطلق و مقایسه نمودارهای پیش‌بینی شده با حالت واقعی تخمین مناسبی را دارا هستند و لذا شبکه عصبی استفاده شده در مطالعه حاضر دارای توانایی قابل قبولی در پیش‌بینی عملکرد آیرودینامیکی بال مثلی است.

### واژه نامه

| علائم اختصاری            | واژه نامه | واژه نامه        |
|--------------------------|-----------|------------------|
| ضریب تعیین               | CE        | معادل انگلیسی    |
| خطای مطلق میانگین        | MAE       | کلمه فارسی       |
| خطای ریشه میانگین مربعات | RMSE      | تابع اساسی شعاعی |
| کلی                      | total     | نیروی لیفت       |
| ارتفاع عمودی زمین تا بال | h         | نیروی درگ        |
| وتر بال                  | c         | گردابه           |
| تابع اساسی شعاعی         | RBF       | لبه فرار         |
| تابع پرسپترون چندلایه    | MLP       | لایه مخفی        |
| تعداد کل داده            | N         | لایه خروجی       |
| ورودی تابع               | I         | بایاس            |
| خروجی تابع               | T         | لایه مرزی        |
| ضریب گسترش               | S         | شبکه عصبی        |
| لونبرگ مارکواردت         | LM        | بال مثلی         |
| نورون چندم               | j         | غیر باریک        |
| گسترش تابع               | $\delta$  | ضریب تعیین       |
| وزن                      | W         | لبه حمله         |
| بردار                    | H         | نورون            |
| ورودی                    | In        | لایه ورودی       |
| خروجی                    | Out       | وزن              |
| ضریب رگرسیون خطی         | $R^2$     | یادگیری ماشینی   |
| ردیف                     | M         |                  |
| ستون                     | N         |                  |
| ورودی یا جهت محور        | X         |                  |
| خروجی یا جهت محور        | Y         |                  |



- [1] J. Whittenbury, "Configuration design development of the navy UCAS-D X-47B," in *AIAA Centennial of Naval Aviation Forum "100 Years of Achievement and Progress"*, 2011, p. 7041.
- [2] K. Wise, "X-45 program overview and flight test status," in *2nd AIAA "Unmanned Unlimited" Conf. and Workshop & Exhibit*, 2003, p. 6645.
- [3] E. L. Houghton and P. W. Carpenter, *Aerodynamics for engineering students*. Elsevier, 2003.
- [4] R. T. Jones, "The minimum drag of thin wings in frictionless flow," *Journal of the Aeronautical Sciences*, vol. 18, no. 2, pp. 75-81, 1951.
- [5] R. Gordnier and M. Visbal, "Higher-order compact difference scheme applied to low sweep delta wing flow," in *41st Aerospace Sciences Meeting and Exhibit*, 2003, p. 620.
- [6] G. Taylor and I. Gursul, "Buffeting flows over a low-sweep delta wing," *AIAA journal*, vol. 42, no. 9, pp. 1737-1745, 2004.
- [7] W. Wentz Jr and D. Kohlman, "Vortex breakdown on slender sharp-edged wings," *Journal of Aircraft*, vol. 8, no. 3, pp. 156-161, 1971.
- [8] R. H. Liebeck, "Design of the blended wing body subsonic transport," *Journal of aircraft*, vol. 41, no. 1, pp. 10-25, 2004.
- [9] R. M. Cummings and A. Schütte, "Integrated computational/experimental approach to unmanned combat air vehicle stability and control estimation," *Journal of Aircraft*, vol. 49, no. 6, pp. 1542-1557, 2012.
- [10] S. Yayla, C. Canpolat, B. Sahin, and H. Akilli, "The effect of angle of attack on the flow structure over the nonslender lambda wing," *Aerospace Science and Technology*, vol. 28, no. 1, pp. 417-430, 2013.
- [11] H. Wen, S. Sang, C. Qiu, X. Du, X. Zhu, and Q. Shi, "A new optimization method of wind turbine airfoil performance based on Bessel equation and GABP artificial neural network," *Energy*, vol. 187, p. 116106, 2019.
- [12] N. M. Alexandrov and M. Y. Hussaini, "Multidisciplinary design optimization: State of the art," 1997.
- [13] A. Jameson, L. Martinelli, and N. A. Pierce, "Optimum aerodynamic design using the Navier-Stokes equations," *Theoretical and computational fluid dynamics*, vol. 10, no. 1, pp. 213-237, 1998.
- [14] J. Reuther and A. Jameson, "Aerodynamic shape optimization of wing and wing-body configurations using control theory," in *33rd aerospace sciences meeting and exhibit*, 1995, p. 123.
- [15] G. Sun, Y. Sun, and S. Wang, "Artificial neural network based inverse design: Airfoils and wings," *Aerospace Science and Technology*, vol. 42, pp. 415-428, 2015.
- [16] M. Rai, "Robust optimal aerodynamic design using evolutionary methods and neural networks," in *42nd AIAA Aerospace Sciences Meeting and Exhibit*, 2004, p. 778.
- [17] A. Verkhatsky, V. Parpura, and J. J. Rodríguez, "Where the thoughts dwell: the physiology of neuronal-glial "diffuse neural net"," *Brain research reviews*, vol. 66, no. 1-2, pp. 133-151, 2011.
- [18] A. Bernstein, A. Kuleshov, Y. Sviridenko, and V. Vyshinsky, "Fast aerodynamic model for design technology," in *Proceedings of West-East High Speed Flow Field Conference (WEHSFF-2007)*, Moscow, Russia, 2007: Citeseer.
- [19] D. Ignatyev, "Simulation of unsteady aerodynamic characteristics of aircraft at high angles of attack using neural networks," in *5-th European Conference For Aeronautics And Space Sciences (EUCASS)*, 2013.
- [20] T. Rajkumar and J. E. Bardina, "Prediction of Aerodynamic Coefficients Using Neural Networks for Sparse Data," in *FLAIRS Conference*, 2002, pp. 242-246.
- [21] C. Zhu, J. Wang, N. Xu, W. Liang, B. Hu, and P. Li, "A Combination Approach of the Numerical Simulation and Data-Driven Analysis for the Impacts of Refracturing Layout and Time on Shale Gas Production," *Sustainability*, vol. 14, no. 23, p. 16072, 2022.
- [22] F. I. A. Rahman, S. Mat, N. H. M. Radzi, M. N. M. Nasir, and R. Sallehudin, "Identification of Sharp Edge Non-Slender Delta Wing Aerodynamic Coefficient Using Neural Network," in *Journal of Physics: Conference Series*, 2021, vol. 2129, no. 1: IOP Publishing, p. 012086.
- [23] S. A. Bagherzadeh, S. Emami Koopaei, and S. A. Salehi, "Optimal Design of Divergent Part of an Over-expanded Nozzle Profile using Artificial Intelligence," *Journal Of Applied and Computational Sciences in Mechanics*, vol. 35, no. 1, pp. 19-36, 2023.

- [24] V. Modanloo, A. Mashayekhi, and B. Akhoundi, "Comparison of regression, bee colony, and artificial neural network for predicting die filling in stamping of bipolar plates fuel cell," *Journal Of Applied and Computational Sciences in Mechanics*, vol. 36, no. 2, pp. 47-58, 2024.
- [25] M. Zamani Mohiabadi, F. Soltani, A. R. Boroomandpour, and G. A. Sheikhzadeh, "Flow prediction in two-dimensional asymmetric diffuser by neural network and comparison with three turbulence models and experimental data," *Journal Of Applied and Computational Sciences in Mechanics*, vol. 34, no. 2, pp. 45-60, 2022.
- [26] H. Kalani and A. Akbarzadeh, "Application of Reinforcement Learning for Navigation of a Planar Snake Robot in Serpentine Locomotion," *Journal Of Applied and Computational Sciences in Mechanics*, vol. 26, no. 1, pp. 97-118, 2015.
- [27] S. Fathi and H. Sadeghi, "Improvement of the five-hole probe calibration using artificial neural networks," *Flow Measurement and Instrumentation*, vol. 86, p. 102189, 2022.
- [28] S. Tümse, M. O. Tasci, I. Karasu, and B. Sahin, "Effect of ground on flow characteristics and aerodynamic performance of a non-slender delta wing," *Aerospace Science and Technology*, vol. 110, p. 106475, 2021.
- [29] S. TÜMSE, M. BİLGİLİ, and B. ŞAHİN, "Lift coefficient estimation of a Delta wing under the ground effect using artificial neural network," *Çukurova Üniversitesi Mühendislik Fakültesi Dergisi*, vol. 36, no. 3, pp. 625-636, 2021.