

داده کاوی با استفاده از شبکه عصبی GRNN بر روی نتایج کالیبراسیون تونل باد

محمد رضا حسنی آهنگر ، ناصر مزینی و محمدرضا سلطانی

۱- مرکز تحقیقات قدر - دانشجوی دکتری دانشگاه علم و صنعت ایران

۲- استادیار دانشکده مهندسی کامپیوتر- دانشگاه علم و صنعت ایران

۳- استاد دانشکده مهندسی هوافضا- دانشگاه صنعتی شریف

E-mail: mrhassani@iust.ac.ir

چکیده - قبل از استفاده عملی از تونل باد همانند سایر سیستمهای اندازه گیری و شبیه سازی باید آنرا با دقت بالا کالیبره نمود، بدست آوردن پارامترهای جریان عبوری از محفظه آزمون تونل باد مانند توزیع سرعت و فشار، یکنواختی و زاویه جریان، دقت اطلاعات و غیره در حین فرآیند کالیبراسیون تونل باد بسیار مهم و حیاتی می باشد. انجام آزمونهای مدل اجسام پرنده در تونل بادی با شرایط جریانی مناسب نقش عمده‌ای در ایجاد اعتماد صنایع وابسته به آن را به همراه خواهد داشت. این فرآیند به دلیل داشتن طیف وسیعی از عدد ماخ و محفظه آزمون نسبتاً بزرگ تونل باد مورد نظر بسیار زمانبر و پرهزینه است. در این مقاله با اعمال روش داده کاوی مبتنی بر شبکه عصبی *GRNN* روی نتایج کالیبراسیون تونل باد و آموزش این شبکه، تعداد دفعات آزمون را تقلیل داده و نهایتاً هزینه و زمان انجام آزمونها برای کالیبراسیون تونل باد را به شدت کاهش دادیم.

کلید واژه- داده کاوی، شبکه عصبی، کالیبراسیون تونل باد، GRNN


۱- مقدمه

طراحی و بهینه سازی شکل آیرودینامیکی هواپیماها، موشکها، خودروها و دیگر اجسام متحرک در داخل اتمسفر یک بحث بسیار پیچیده می‌باشد که به سختی می‌توان آن را بطور دقیق مدل ریاضی نمود. بنابراین در بسیاری مواقع این حرکت در داخل تونل باد شبیه‌سازی شده و پارامترهای نیرو و لنگر مورد نظر طراح جسم پرنده اندازه‌گیری می‌شود [۴،۳]. قبل از استفاده عملی از تونل باد باید پارامترهای جریان عبوری از محفظه آزمون آنرا با دقت بالا اندازه گیری نمود [۴،۵]، با توجه به اینکه تونل باد مورد نظر یک تونل باد سه منظوره و محفظه آزمون نسبتاً بزرگ می‌باشد. بدست آوردن پارامترهای اصلی جریان عبوری از محفظه آزمون تونل باد مانند توزیع سرعت و فشار و دقت اطلاعات در حین فرآیند کالیبراسیون تونل باد نیاز به صرف هزینه و زمان بسیار زیادی دارد. به همین دلیل در این مقاله از روشی هوشمند مبتنی بر شبکه عصبی *GRNN* را جهت تحلیل و تعمیم اطلاعات استفاده می‌شود یعنی با گرفتن پارامترهای اصلی جریان عبوری در بعضی از نقاط محفظه آزمون در بعضی از عدد ماخ می‌توان با آموزش شبکه بوسیله این داده‌ها پارامترهای اصلی جریان عبوری در

در سالهای اخیر اشتیاق فراوانی جهت بهره‌گیری از هوش محاسباتی (شبکه عصبی، منطق فازی و الگوریتم ژنتیک) در حل بسیاری از مسائل موجود در صنایع و علوم مختلف بوجود آمده است. شبکه‌های عصبی (*Neural Network*) امروزه در طیف وسیعی از علوم از جمله هوافضا کاربرد پیدا کرده است [۱].

شبکه (*GRNN (General Regression Neural Network)*) یک شبکه عصبی سه لایه است که می‌تواند در حالت کلی جهت تخمین هر نوع تابع غیر خطی بکار رود. از نظر قدرت، تخمین این شبکه معادل شبکه چند لایه فید فوروارد است که در بعضی موارد نیز بهتر از آن عمل می‌کند و در عین حال دارای این امتیاز بزرگ است که آموزش آن بسیار سریع و تنها با یک مرتبه تکرار انجام می‌شود [۲]. این خاصیت، آن را جهت تخمین توابعی که معادله آنها با زمان تغییر می‌کند، مناسب می‌نماید و سبب می‌شود تا بتواند برای تخمین سیستمهایی با دینامیک متغیر مانند خروجی نتایج کالیبراسیون تونل باد نیز بکار رود.

برای کالیبراسیون این تونل باد از ابزارهای مختلفی از جمله ریک، لوله پیتوت، سنسورهای فشار، سیستم نگهدارنده و جابجاکننده ریک و غیره که شکل (۳) قسمتی از آنها را نشان می دهد، استفاده شده است.



شکل-۳: شمای ریک و نمای ورودی تونل باد ST2. (الف) ریک و سنسور فشار (ب) نمای جلوی ریک نصب شده در تونل باد

۳- مبانی ریاضی شبکه GRNN

فرض کنید ورودی ها و خروجی های یک سیستم، بردارهای x ، y و تعداد محدودی نمونه مشاهده شده، (x^i, y^i) به عنوان زوجهای ورودی-خروجی موجود باشند. تخمین متغیر وابسته y به متغیر مستقل ورودی x ، عبارتست از امید ریاضی متغیر وابسته y به شرط داشتن متغیر مستقل x $(E(y|x))$ ، بیانگر تخمین تابع در نقطه x خواهد بود. با فرض معلوم بودن تابع چگالی احتمال بین x و y $f(x,y)$ تخمین متغیر خروجی y به ازاء ورودی x به شکل رابطه (۱) تعریف می شود:

$$E(y|x) = \frac{\int_{-\infty}^{\infty} y f(x, y) dy}{\int_{-\infty}^{\infty} f(x, y) dy} \quad (1)$$

شبکه GRNN بر مبنای تعیین تابع $f(x, y)$ از روی نمونه های مشاهده شده ورودی-خروجی با کمک تخمین زندهای غیر پارامتری یک بعدی و چند بعدی که توسط پارزن (Parzen) و کاکولوس (Cacoullos) پیشنهاد شده اند، انجام می دهد [۲]. این تخمین زندها انتخاب مناسبی برای تخمین تابع چگالی احتمال خواهد بود مشروط بر آنکه فرض شود تابع احتمال پراگندگی واقعی، پیوسته است و مشتقات جزئی مرتبه اول تابع f در تمام نقاط x اعداد کوچکی هستند.


با این فرضیات و با در نظر گرفتن یک مجموعه مشاهدات از ورودی-خروجیها $\{(x^i, y^i) | i = 1, \dots, m\}$ که در آنها

نقاط دیگر محفظه آزمون و عدد ماخ را بوسیله شبکه عصبی تخمین و بدست آورد و نیازی به انجام آزمون در تمام ابعاد محفظه آزمون و در تمام رنج عدد ماخ نخواهد بود. این مطلب سبب کاهش چشمگیری در هزینه و زمان مورد نیاز برای کالیبراسیون تونل باد می شود.

ساختار مقاله در ادامه بدین شرح است که ابتدا تونل باد ST2 و تجهیزات آن جهت کالیبراسیون و مبانی ریاضی شبکه GRNN، ساختار شبکه GRNN و دلایل استفاده از شبکه GRNN بجای روشهای متداول در تخمین توابع غیرخطی تشریح می گردد. نهایتاً طبقه اعمال شبکه عصبی به نتایج و تخمین آنها، چند نمونه نتایج ارائه و با خلاصه و نتیجه گیری به پایان می رسد.


۲- تونل باد ST2 و تجهیزات آن جهت کالیبراسیون

تونل باد مورد نظر از نوع مدار باز، مکنده و پیوسته بوده و دارای محفظه آزمون به ابعاد $60 * 60 * 144$ سانتی متر است و قابلیت انجام آزمون مدل جسم پرنده را در سه رژیم مادون صوت (Subsonic)، گذر صوت (Transonic) و مافوق صوت (Supersonic) را دارد. شکل (۱) نمای کلی محفظه آزمون تونل باد را نشان می دهد [۳].



شکل-۱: شمای کلی محفظه آزمون تونل باد ST2.

همچنین می توان ضرایب آیرودینامیکی مدلی از جسم پرنده و توزیع فشار بر روی آن را در حالت های استاتیکی و دینامیکی بوسیله سیستم اخذاطلاعات، به همراه بالانس یا سنسورهای فشار را مطابق شکل (۲) در داخل تونل باد اندازه گیری نمود [۳].



شکل-۲: شمای کلی سیستم اخذاطلاعات تونل باد ST2.

فرض کنید محدوده مورد نظر از فضای ورودی R^P را به m خوشه تقسیم نموده ایم. اگر در i امین خوشه از فضای ورودی، N_i نمونه ورودی- خروجی قرار گرفته باشند، هر یک از خوشه ها را تنها با یک تابع نمایی و به کمک مرکز آن خوشه نمایش می دهیم [۲]. چنانچه این تغییرات را اعمال کنیم، رابطه (۵) تخمین شبکه GRNN به رابطه (۵) تبدیل می گردد:

$$y_e(x) = \frac{\sum_{i=1}^m A^i \exp(-\frac{D_i^2}{2\sigma^2})}{\sum_{i=1}^m B^i \exp(-\frac{D_i^2}{2\sigma^2})} \quad \begin{aligned} A(k) &= A(k-1) + y^j \\ B(k) &= B(k-1) + 1 \end{aligned} \quad (5)$$

A^i در رابطه فوق، مجموع خروجیهای مشاهده شده مربوط به خوشه i ام و B^i تعداد نمونه های واقع شده در خوشه i ام می باشد. با توجه به اینکه معمولاً سرعت تطبیق شبکه با شرایط متغیر سیستم بسیار با اهمیت می باشد و آموزش زمان حقیقی شبکه بر اساس نمونه های دریافتی از سیستم در هر لحظه مورد نظر است، این روابط به دلیل متوسط گیری و تاخیر در پاسخ، استفاده نمی شود. در واقع شکل جدیدی از رابطه تخمین که ترکیبی از روابط قبلی می باشد، مورد استفاده قرار می گیرد. به این ترتیب که ابتدا فضای ورودی به m خوشه تقسیم می شود و سپس با دریافت هر نمونه ورودی- خروجی جدید، پس از تشخیص اینکه نمونه متعلق به خوشه i ام است، خروجی مربوطه مستقیماً بجای A^i جایگزین می شود [۲]. یعنی رابطه (۶) بدست می آید:

$$y_e(x) = \frac{\sum_{i=1}^m A^i \exp(-\frac{D_i^2}{2\sigma^2})}{\sum_{i=1}^m \exp(-\frac{D_i^2}{2\sigma^2})} \quad \text{و} \quad A^i = y^i \quad (6)$$

یعنی چنانچه i امین نمونه ورودی- خروجی (با خروجی y^j متعلق به خوشه i ام باشد، طبق رابطه فوق A^i را تغییر می دهیم. بدلیل آنکه متوسط گیری از مقادیر خروجی انجام نمی شود و خروجیها مستقیماً جایگزین A^i می گردند، همه B^i ها برابر یک خواهند بود. چنانچه مشاهده می شود، این رابطه از مزایای روابط قبلی بطور همزمان سود می برد، چنانچه در تابع تخمین زننده تابع چگالی احتمال یعنی در تابع $f_m(x, y)$ بجای

بردارهای P بعدی ورودی و y^i ها اعداد اسکالر خروجی هستند، تخمین زندهای غیر پارامتری $f_m(x, y)$ را بر مبنای توابع گوسی بصورت رابطه (۲) تعریف می شود:

$$f_m(x, y) = \frac{1}{(2\pi)^{(P+1)/2} \sigma^{(P+1)}} \sum_{i=1}^m \exp\left[-\frac{(x-x^i)^T(x-x^i)}{2\sigma^2}\right] \exp\left[-\frac{(y-y^i)^2}{2\sigma^2}\right]$$

توابع f_m به فرم فوق، در تمام نقاط (x, y) به شرط آنکه f در آن نقطه پیوسته باشد و پارامتر σ به صورت تابع نزولی از m تغییر نماید بگونه ای که شرایط رابطه (۳) را ارضا نماید:

$$\lim_{m \rightarrow \infty} \sigma(m) = 0 \quad (3)$$

$$\lim_{m \rightarrow \infty} m\sigma^p(m) = \infty$$

برای به دست آوردن $y_e(x)$ تخمین y بر حسب ورودی x ، کافیهست تخمین تابع احتمال پراگندگی یعنی $f_m(x, y)$ را به جای تابع احتمال پراگندگی واقعی $f(x, y)$ در معادله تخمین رابطه (۱) جایگزین شده و با تعریف تابع عددی D و با محاسبه انتگرالها که پس از ساده کردن آن به شکل نهایی رابطه (۴) در می آید [۲، ۶]:

$$y_e(x) = \frac{\sum_{i=1}^m y^i \exp(-\frac{D_i^2}{2\sigma^2})}{\sum_{i=1}^m \exp(-\frac{D_i^2}{2\sigma^2})} \quad \text{و} \quad D_i^2 = (x-x^i)^T(x-x^i) \quad (4)$$

مشاهده می شود که در رابطه بدست آمده، تخمین خروجی به ازاء ورودی x بصورت یک متوسط وزن دار مقادیر مختلف y^i بدست آمده است در واقع میزان تاثیر y^i بر روی تخمین خروجی به فاصله x و x^i (یعنی D^i) و به شیب تغییرات تابع گوسی که پارامتر σ تعیین کننده آن می باشد، وابسته است [۲].

۴- خوشه یابی ورودی ها و تطبیق شبکه با شرایط متغیر

شبکه GRNN به ازاء هر نمونه ورودی- خروجی، یک جمله نمایی در نظر گرفته می شود. اگر تعداد نمونه ها خیلی زیاد شوند، نیاز به حافظه زیادی برای نگهداری نمونه ها، تعداد جملات جمع شونده بیشتر بوده و علاوه بر آن زمان محاسبات بسیار طولانی می گردد. به همین دلیل لازم است که از روشهای مختلف خوشه یابی اطلاعات، جهت ایجاد خوشه های مختلف در فضای ورودی، استفاده شود [۲، ۷].

توان دوم $(x - x^i)$ از قدر مطلق آن استفاده شود، معادله (۷) به معادله زیر تبدیل می شود.

$$y_e(x) = \frac{\sum_{i=1}^m A^i \exp(-\frac{C_i}{\sigma})}{\sum_{i=1}^m \exp(-\frac{C_i}{\sigma})} \text{ و } C_i = \sum_{j=1}^p |x_j - x_j^i| \quad (۷)$$

خروجی مربوطه مستقیماً بجای A^i جایگزین می شود و x_j و x_j^i عناصر زام بردارهای x و $x_j - x_j^i$ می باشند [۶،۷].

۵- ساختار شبکه GRNN و تعمیم آن به حالت چند خروجی

شبکه GRNN شبکه ای است سه لایه که نرونهای لایه اول آن را واحدهای الگو نامیده که عمل محاسبه $|x - x^i|$ و تابع تحریک نمایی را انجام می دهند. نرون i ام از این لایه، نماینده خوشه i ام در فضای ورودی و حاوی مقدار x^i (مرکز خوشه i ام) می باشد و خروجی این نرون مقدار $\exp(-\frac{C_i}{\sigma})$ است. بنابراین تعداد نرونهای لایه اول برابر m (تعداد خوشه ها) می باشد. نرونهای لایه دوم را واحدهای جمع کننده نامیده و شامل دو نرون است که عمل ضرب داخلی بردارهای $A = [A^i] ; i = 1, \dots, m$ و $B = [B^i] ; i = 1, \dots, m$ با بردار خروجی لایه اول یعنی:


$$C = \exp(-\frac{C_i}{\sigma}); i = 1, \dots, m$$

را انجام می دهند. به عبارت دیگر خروجی نرونهای لایه دوم به ترتیب عبارتند از:

$$\sum_{i=1}^m A^i \exp(-\frac{C_i}{\sigma}) \text{ و } \sum_{i=1}^m B^i \exp(-\frac{C_i}{\sigma})$$

یعنی صورت و مخرج کسر تابع تخمین، توسط این دو نرون محاسبه می گردد. نرونهای لایه آخر را واحدهای خروجی تشکیل می دهد. که عمل تقسیم خروجیهای نرونهای لایه دوم و محاسبه مقدار نهایی تخمین یعنی $y_e(x)$ را انجام می دهد. در ضمن واحدهای ورودی فقط به عنوان بافر عمل می کنند و نرون محسوب نمی شوند [۲،۸].

چنانکه از روابط تخمین شبکه GRNN مشخص است، خروجی تابع تخمین اسکالر می باشد. اما با تغییرات مختصری در این شبکه می توان به سهولت آن را برای توابع چند خروجی نیز بکار برد [۲،۶]، شکل (۴) ساختار شبکه GRNN را با این توسعه نشان می دهد. این شبکه قادر است در حالت کلی یک تابع غیر خطی g از R^p به R^n را شبیه سازی نماید. بنابراین طبیعی است که هر یک از این توابع را می توان توسط شبکه تخمین زد. با توجه به مشترک بودن دامنه ورودی g_1 و g_2 واضح است که لایه اول شبکه GRNN برای این دو تابع مشترک خواهد بود و تنها نرونهای لایه دوم و سوم باید به شبکه اضافه شوند (دو نرون اضافه برای لایه دوم و یک نرون اضافه برای لایه سوم).



شکل-۴: ساختار شبکه GRNN و تعمیم آن به حالت چند خروجی

آموزش شبکه در حالت چند خروجی نیز کاملاً شبیه به حالت تک خروجی و تنها با یک بار تکرار صورت می گیرد. در حالیکه آموزش انواع دیگر شبکه های عصبی، با افزایش تعداد خروجیهای آنها، معمولاً بسیار مشکلتر می شود [۲].

۶- دلایل استفاده از شبکه GRNN بجای روشهای متداول در تخمین توابع غیر خطی

شبکه GRNN در واقع یک روش تخمین توابع غیر خطی را پیشنهاد می نماید که مزایای زیادی نسبت به سایر روشهای تخمین معمول در ریاضیات دارد. روشهای متداول تخمین معمولاً به یکی از دو روش زیر عمل می نمایند [۲]:

در روش اول یک تابع معین برای یک مسئله مشخص انتخاب می‌گردد که دارای تعدادی پارامتر مجهول است. با استفاده از نمونه‌های ورودی-خروجی مشاهده شده از تابع تحت بررسی و بکارگیری روشهای آماری، ضرایب و پارامتری‌های مجهول تعیین می‌شوند و مدلی جهت تخمین تابع تحت بررسی حاصل می‌گردد. ایراد اصلی این روش، نیاز به حدس زدن و یا دانستن تابع معین، در هر مسئله به طور جداگانه است. بگونه‌ای که اگر این تابع به درستی انتخاب نشود و یا با مجموعه آموزشی ورودی تطبیق نداشته باشد، عمل تخمین تابع مورد نظر بسیار مشکل و در بعضی موارد غیر ممکن خواهد شد. اما چنانچه بتوان تابع مناسبی در ابتدای تخمین فرض نمود، تعداد پارامترهای مجهول کم شده و تعیین آنها ساده تر می‌گردد.

روش دوم استفاده از چندجمله‌ایها برای تخمین توابع است. به این معنی که برای تخمین یک تابع تحت بررسی، ابتدا درجه چندجمله‌ای و تعداد متغیرهای مستقل آن را مشخص می‌کنند. سپس با استفاده از نمونه‌های ورودی-خروجی، ضرایب مجهول چندجمله‌ای را محاسبه می‌نمایند. روش چندجمله‌ای معمولاً در درجات کوچک و تعداد پایین متغیرهای مستقل، قابل استفاده است. زیرا در مسائل پیچیده با درجه و تعداد متغیرهای بالا، تعداد پارامترهای مجهول چندجمله‌ای معمولاً به تعداد نمونه‌های آموزشی زیادی نیاز دارد که حتی در چنین حالتی نیز، تضمینی جهت قدرت تعمیم دهی مناسب چندجمله‌ای وجود ندارد. یعنی ممکن است یک چندجمله‌ای کوچکی از خطا در نقاط آموزشی ایجاد نماید اما در رویارویی با ورودیهای جدید اطمینانی از کوچک بودن خطاها موجود نیست.

هر دو روش فوق، از روشهای پارامتری تخمین توابع محسوب می‌شوند. زیرا مبتنی بر تعیین تعدادی پارامتر مجهول می‌باشند. اما بنا بر توضیحات ارائه شده در مورد شبکه GRNN این شبکه یک تخمین زن غیر پارامتری است و نیاز به فرض هیچ تابع معینی در ابتدای کار ندارد بلکه نمونه‌های ورودی-خروجی دریافتی، مستقیماً به عنوان وزنه‌های شبکه مورد استفاده قرار می‌گیرند. شبکه قادر به کار کردن با تعداد نمونه‌های کم و تعداد نمونه‌های زیاد با انتخاب مناسب تنها یک پارامتر، یعنی σ می‌باشد. بطوریکه در حالت حدی، هنگامیکه $m \rightarrow \infty$ برود، تابع

تخمین به سمت تابع واقعی میل می‌کند (به شرط آنکه σ با حفظ شرایط گفته شده به سمت صفر میل کند). بنابراین شبکه GRNN نیاز به تعداد زیادی نمونه ورودی-خروجی جهت انجام تخمین ندارد، به گونه‌ای که حتی با یک نمونه آموزشی نیز، این شبکه تخمینی کاملاً منطقی از تابع تحت بررسی بدست می‌آورد. به همین دلیل شبکه GRNN برای تخمین رفتار یک سیستم بصورت زمان حقیقی، هنگامیکه اطلاعات ورودی-خروجی سیستم به تدریج بدست می‌آیند، کاملاً مناسب می‌باشد [۸].


۷- طریقه اعمال شبکه عصبی به نتایج و تخمین آنها

برای آنالیز و تعیین رفتار جریان در نقاطی که تست انجام نشده، از شبکه GRNN استفاده شده است برای اعمال این شبکه به نتایج آزمایش، نیازمند تعیین ورودی‌ها به شبکه می‌باشیم. ورودی‌های شبکه GRNN شامل مختصات سه بعدی نقاط داده برداری شده از محفظه آزمون تونل باد و خروجی که برای آموزش شبکه به کار می‌رود، اعداد ماخ یا فشار اخذ شده در آن نقاط می‌باشد.

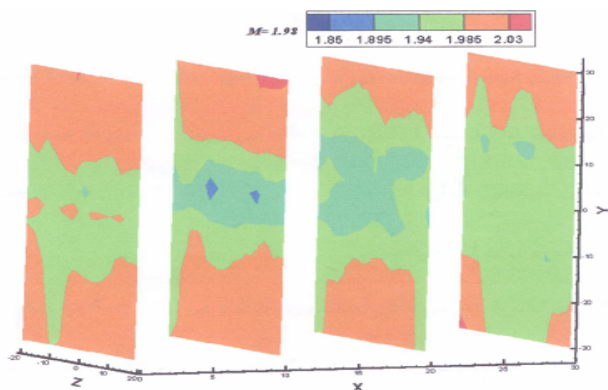
به همین منظور یک برنامه در جعبه ابزار شبکه عصبی (NN) در مطلب (MATLAB) و براساس ایده نرم افزار مراجع [۹، ۱۰] نوشته شده است که ابتدا داده‌های خام مختصات و خروجی سنسورهای فشار را در دو ماتریس جهت تحلیل و ارزیابی آماده نموده و سپس شروع به آموزش شبکه با این نقاط می‌نماید و در نهایت با استفاده از شبکه آموزش دیده شده پارامترهای نقاطی که آزمونی برایشان انجام نشده است تخمین زده می‌شود.

برای آزمایش نتایج تخمین زده شده توسط شبکه عصبی کافی بود یکی از مقاطع داده برداری شده را در مرحله آموزش شبکه در آن دخالت نداده و سپس آن مقطع مورد نظر را به صورت تخمین از شبکه گرفته و با مقطع واقعی مقایسه کرد. نتایج بدست آمده از این الگو تفاوت فاحشی را بین مقاطع تخمین زده شده با شبکه عصبی و مقادیر واقعی نشان می‌دهد.

پس از آموزش شبکه، مقاطع طولی مابین مقاطع تست شده را براحتی می‌توان با شبکه تخمین زد نکته قابل توجه این است که پارامتر δ ، در کیفیت تخمین شبکه عصبی از نقاط میانی داده‌ها تاثیر بسزایی دارد. بنابراین با تغییر مقادیر δ ،




شکل ۵- کانتورهای واقعی عدد ماخ از نقاط اندازه گیری شده در محفظه آزمون در عدد ماخ ۱/۹۸



شکل ۶- کانتورهای عدد ماخ تخمین زده شده با شبکه عصبی در همان مقاطع کانتورهای واقعی در عدد ماخ ۱/۹۸

با مقایسه این دو شکل مشاهده می‌شود که شبکه عصبی با تخمین بسیار خوبی کانتورهای عدد ماخ را حدس زده است. پس از اطمینان به تخمین درست شبکه عصبی از مقاطع واقعی، حال در شکل (۷) مقادیر عدد ماخ در صفحات میانی آنها رسم شده است. همانطور که انتظار می‌رود این کانتورها همه خواص کانتورهای واقعی را دارا می‌باشد.



شکل ۷- کانتورهای عدد ماخ تخمینی توسط شبکه عصبی در مقاطع بین مقاطع واقعی در عدد ماخ ۱/۹۸

می‌توان نتایج تخمین زده شده را تغییر داد. برای بدست آوردن δ بهینه از روش زیر استفاده شده است:

۱- این روش مبتنی بر حذف بعضی داده‌ها در مرحله آموزش شبکه عصبی است، که با تغییر پارامتر δ ، داده‌های حذف شده توسط شبکه عصبی تخمین زده و با مقادیر واقعی آن مقایسه می‌شود و آنقدر پارامتر δ را می‌توان تغییر داد تا اختلاف مقادیر تخمین زده شده با مقادیر واقعی به حداقل برسد، که البته این روش زیاد مناسب نیست چون در هر مرحله که تعدادی از داده‌ها را در مرحله آموزش کم می‌کنیم، شکل کل شبکه عصبی تغییر می‌کند و شاید در نهایت که از همه داده‌ها برای آموزش استفاده شود، δ بدست آمده برای آن، با δ بدست آمده برای شبکه قبلی اختلاف داشته باشد.

۲- این روش مینیمم کرده پارامتری به نام E می‌باشد که بصورت رابطه (۸) تعریف می‌شود:

$$E_{mean} = \frac{\sum_{i=1}^k |y_e(x^i) - y^i|}{k} \quad (8)$$

که $y_e(x^i)$ خروجی تخمین زده شده به ازاء ورودی x^i و یا همان عدد ماخ تخمینی شبکه عصبی است و y^i خروجی واقعی یا عدد ماخ واقعی نقاط مورد نظر و k تعداد خروجی‌ها می‌باشد. با تغییر پارامتر δ می‌توان مینیمم را بدست آورد و بدین ترتیب δ بهینه بدست می‌آید.

روش اخیر برای بدست آوردن δ ، روش مناسبی می‌باشد، که با اعمال این روش δ بهینه در عدد ماخ ۲ مقدار ۲/۵ و در عدد ماخ ۱/۵ مقدار ۱ بدست آمد.

۸- چند نمونه نتایج

بررسی و تحلیل پارامترهای اصلی جریان عبوری روی فایل‌های خروجی آزمون کالیبراسیون تونل باد در چند عدد ماخ انجام گرفته که نتایج تحلیل در دو عدد ماخ ۱/۵ (۱/۴۷) و ۲ (۱/۹۸) در دو حالت واقعی و تخمین زده شده بوسیله شبکه عصبی GRNN با رسم نمودارهای کانتور بصورت برشهای صفحه‌ای بعنوان نمونه، ارائه می‌گردد.

شکل‌های (۵) و (۶) کانتورهای عدد ماخ در نقاط تست شده در تونل باد در عدد ماخ ۲ برای حالت واقعی و حالت تخمین زده شده با شبکه GRNN را نشان می‌دهد.


شکل‌های (۸) و (۹) کانتورهای عدد ماخ در نقاط تست شده در تونل باد در عدد ماخ ۱/۵ برای حالت واقعی و حالت تخمین زده شده با شبکه GRNN و شکل (۱۰) مقادیر عدد ماخ در صفحات میانی آنها را نشان می‌دهد. همانطور که مشاهده می‌شود نتایج قبل را به ما می‌دهد یعنی اختلاف بسیار کمی در کیفیت این دو شکل دیده می‌شود.

۹- نتیجه گیری


در این مقاله روشی جدید مبتنی بر شبکه عصبی جهت آموزش و سپس تخمین و تعمیم روی نتایج داده های کالیبراسیون تونل باد باد مطرح شد و نتایج بکارگیری این روش بصورت نمونه در دو عدد خ ماخ ارائه و مورد تحلیل و ارزیابی قرار گرفت، نتایج ارائه شده نشان از تخمین بسیارخوب شبکه GRNN در تولید پاسخ برای نقاطی که داده برداری نشده است، دارد. این روش سبب کاهش تعداد دفعات آزمون می شود و نهایتا هزینه و زمان انجام آزمونها برای کالیبراسیون تونل باد را به شدت کاهش می دهد.

مراجع


- [1] Wang k, "Intelligent Condition Monitoring and Diagnosis systems", A Computational Intelligence Approach, IOS Press, Ohmsha, 2003.
- [۲] Specht, D. F, "A General Rgression Neural Network ", IEEE Transactiona on Neural Network. Vol.2, No.6, Nov 1991.
- [3] Kangavari M.R, Hassani Ahangar M.R and Berangi R. "Investigation of error sources on the Balance and the standard dynamic model in the wind tunnel", ICAS Conference, Hamburg Germany, 3-8 September 2006.
- [4] Pope A, Goin K L., "High Speed Wind Tunnel Testing", John Wiley & Sons, New York, Third Edition 1999.
- [5] Edwards. A T., "Comparison of Strain Gage and Fiber Optic Sensors on a Sting Balance in a Supersonic Wind Tunnel" , Master of Science Thesis, Virginia University, Dec. 2000.
- [6] K.S. Narendra & K.Parthasarathy, "Identification & Control of dynamical System Using Neural Networks ", IEEE Trans.Neural Networks Vol.1 pp4-27 Mar 1990.
- [7] Leea.W.Y and Houseb J , "Subsystem level fault diagnosis of a building's air-handling unit using general regression neural networks ", Korea Institute of Energy Research, Applied Energy, Vol.77, PP-153-170, April 2004.
- [8] Rutkowski. L , "Generalized Regression Neural Networks in Time-Varying Environment", IEEE Transactiona on Neural Network. Vol.15, No.3, May 2004.
- [9] Kanevski M and Timonin V, "General Regression Neural Network, Anisotropic module GRNN_2 user manual ", IGAR Research Repor, No. G02-2006, March, 2006.
- [10] WWW.Unil.ch/IGAR



شکل-۸ کانتورهای واقعی عدد ماخ از نقاط اندازه گیری شده در محفظه آزمون در عدد ماخ ۱/۴۷



شکل-۹ کانتورهای عدد ماخ تخمین زده شده با شبکه عصبی در همان مقاطع کانتورهای واقعی در عدد ماخ ۱/۴۷



شکل-۱۰ کانتورهای عدد ماخ تخمینی توسط شبکه عصبی در مقاطع بین واقعی در عدد ماخ ۱/۴۷