



Dynamic modeling of surface vessel maneuvering based on deep learning using recurrent neural networks

Amirhossein Najari¹, Mohammad Saeed Seif^{2*} 

¹ PhD Candidate, Sharif University of Technology; amirhossein.najari@mech.sharif.edu

² Faculty of Mechanical Engineering, Sharif University of Technology; seif@sharif.edu

ARTICLE INFO

Article History:

Received: 22 May 2025

Last modification: 25 Jul 2025

Accepted: 27 Jul 2025

Available online: 27 Jul 2025

Article type:

Research paper

Keywords:

System Identification

Recurrent Neural Network Simultaneous

Simulation and Identification

ABSTRACT

Today, Unmanned Surface Vehicles (USVs) are used in a wide range of maritime operations. Designing the control system and simulating the maneuvering behavior of such vessels prior to actual deployment is of great importance. Therefore, it is essential to extract an accurate dynamic model for each vessel. There are various methods available to derive a vessel's maneuvering dynamics. However, due to the complexity and nonlinear effects present in vessel dynamics, deriving the model using equations of motion and hydrodynamics is relatively challenging. In recent years, the use of artificial neural networks for modeling vessel dynamics has become a suitable alternative to traditional methods, reducing the need for detailed understanding and application of hydrodynamic equations. In this study, the dynamic relationship between the rudder angle and the yaw rate is modeled using a trained artificial neural network. Since real-world testing conditions were not available, a computer simulation model of the vessel in the Simulink environment was utilized. The network was trained using data from zigzag maneuver tests, and then evaluated using input types different from the training data, such as sinusoidal and sawtooth signals.

ISSN: 2645-8136



DOI:

Copyright: © 2025 by the authors. Submitted for possible open access publication under the terms and conditions of the Creative Commons Attribution (CC BY) license [<https://creativecommons.org/licenses/by/4.0/>]



مدلسازی دینامیکی مانور شناور سطحی مبتنی بر یادگیری عمیق با استفاده از شبکه عصبی بازگشتی

امیرحسین نجاری^۱، محمدسعید سیف^۲ 

^۱ دانشجوی دکتری/ دانشگاه صنعتی شریف، amirhossein.najari@mech.sharif.edu

^۲ استاد تمام/ دانشگاه صنعتی شریف، seif@sharif.edu

چکیده

امروزه شناورهای بدون سرنشین سطحی در طیف وسیعی از عملیات‌های دریایی کاربرد دارند. طراحی سیستم کنترل و شبیه سازی مانور این دسته شناورها قبل از اجرای عملیات از اهمیت بالایی برخوردار است از این جهت لازم است تا مدل دینامیکی دقیقی برای هر شناور استخراج گردد. روش های متعددی برای دست یابی به مدل دینامیکی مانور شناور وجود دارد. باتوجه به پیچیدگی ها و اثرات غیرخطی موجود در دینامیک شناور، استخراج مدل آن از معادلات حرکت و هیدرودینامیک نسبتا دشوار است. استفاده از شبکه های عصبی مصنوعی به منظور مدلسازی دینامیک شناور در سال های اخیر جایگزین مناسبی برای روش های سنتی بوده و در آن نیاز به درک معادلات هیدرودینامیک و بکارگیری آنها برای استخراج مدل دینامیکی کم رنگ تر شده است. در این پژوهش بااستفاده از آموزش یک شبکه عصبی مصنوعی مدل دینامیک میان زاویه سکان و نرخ حرکت سمتی استخراج می شود. باتوجه به در دسترس نبودن شرایط برای اجرای تست واقعی از یک مدل کامپیوتری تهیه شده برای شناور در محیط سیمولینک استفاده می شود و با استفاده از داده های تست زیگزاگ شبکه آموزش استاتیک و دینامیک داده می شود، سپس شبکه آموزش داده شده با ورودی های متفاوت از ورودی آموزش مثل ورودی سینوسی و دندان اره ای ارزیابی می شود.

اطلاعات مقاله

ناریخچه مقاله:

تاریخ دریافت مقاله: ۱۴۰۴/۰۳/۰۱

تاریخ اصلاح مقاله: ۱۴۰۴/۰۵/۰۳

تاریخ پذیرش مقاله: ۱۴۰۴/۰۵/۰۵

تاریخ انتشار مقاله: ۱۴۰۴/۰۵/۰۵

نوع مقاله:

کلمات کلیدی:

شناسایی سیستم

شبکه عصبی بازگشتی

شبیه سازی و شناسایی همزمان

DOI:

حق نشر: © ۲۰۲۵ توسط نویسندگان. این اثر برای انتشار با دسترسی آزاد، تحت شرایط و ضوابط مجوز (CC BY) ارسال شده است.

ISSN:2645-8136



بخش قابل توجهی از سطح کره زمین را دریاها و اقیانوس ها تشکیل می دهند. از آنجا که منابع قابل توجه انرژی، غذا و مواد معدنی در این محیط ها قرار دارد. اما بخش زیادی از این محیط بدلیل عدم دسترسی نیروی انسانی به طور کامل بررسی و کاوش نشده است [۱]. در سال های اخیر وسایل بدون سرنشین سطحی و زیرسطحی برای عملیات در دریاها و اقیانوس ها طراحی و ساخته شده اند [۲]. در این بین شناورهای بدون سرنشین سطحی در طیف گسترده ای از عملیات های نظامی، پایش محیطی، جستجو و نجات جایگاه یافته اند و استفاده شده اند [۳].

سیستم هدایت، کنترل و ناوبری در این دسته از وسایل بدون سرنشین از اهمیت بالایی برخوردار است. طراحی قابل اطمینان و بهینه یک سیستم کنترل نیازمند مدلسازی دینامیکی شناور و فراهم نمودن امکان شبیه سازی رفتار آن پیش از ورود به محیط واقعی است. مدلسازی دینامیکی یک متحرک می تواند بصورت تحلیلی و بر مبنای قانون دوم نیوتن [۴]، یا با استفاده از تحلیل های مبتنی بر دینامیک سیالات محاسباتی (CFD¹) انجام گردد [۵].

روش شناسایی سیستم و استفاده از تست های میدانی نیز جهت استخراج مدل دینامیکی مورد استفاده قرار می گیرد که باتوجه به استفاده از داده های واقعی شناور، دقت بالاتری نسبت به سایر روش ها دارد. مواقعی که دینامیک سیستم پیچیده و غیرخطی است استفاده از روش های مرسوم شناسایی سیستم که برای تخمین رفتار خطی توسعه یافته اند امکان پذیر نیست. مصنوعی و به طور خاص شبکه های عصبی مصنوعی می تواند راه حلی برای مدلسازی دینامیکی شناور باشد. شبکه عصبی مصنوعی از تعدادی سلول عصبی مصنوعی تشکیل شده است که به وسیله رابط هایی به نام سیناپس که وظیفه آنها انتقال اطلاعات می باشد، با هم در ارتباط هستند. شبکه های عصبی با توانایی قابل توجه خود در استنتاج نتایج از داده های پیچیده، می توانند در استخراج الگوها و شناسایی گرایشهای مختلفی که شناسایی آنها برای انسانها و کامپیوتر بسیار دشوار است استفاده شوند. اهمیت سیستم شبکه عصبی این است که می توان سیستم های پیچیده دینامیکی را بدون داشتن دانش مربوطه و صرفا مبتنی بر داده های تست، مدلسازی کرد. لو و ژانگ در سال ۲۰۱۶ با استفاده از شبکه عصبی حرکات مانور کشتی را مدل کردند [۶]. مشخصه های مانورپذیری و مشتقات هیدرو دینامیکی در این مدل با استفاده از شبکه عصبی دولایه با پیشخور^۲، تعیین شده اند.

در این تحقیق مقادیر ضرایب معادله دیفرانسیل مربوط به حرکت سمتی با استفاده از شبکه عصبی بدست آمده است و در نهایت

مشخصه های مانورپذیری شناور محاسبه شده است. ژینگ و مک کیو در سال ۲۰۱۰ بر اساس رویکرد مبتنی بر شبکه عصبی مدلی برای تطبیق حرکات رول شناور با داده های تجربی ارائه کردند [۷]. دو مدل چند متغیره برای توصیف نیروهای غیرخطی در حرکت رول استفاده شده است، اولی مدلی بر اساس معادلات دیفرانسیل معمولی و دیگری بر اساس معادلات دیفرانسیل کسری که در این مدل مولفه های مشتق کسری برای نشان دادن ممان اینرسی افزوده و میرایی معرفی شده اند. آنالیز استاتیک ۲۰ مورد از نتایج مقایسه ای با داده های تجربی نشان می دهد که مدل مبتنی بر معادلات دیفرانسیل کسری بهتر از مدل مبتنی بر فیزیک سیستم است. زاگان و همکاران در سال ۲۰۱۴ سعی کردند که با استفاده از وضعیت فعلی شناور و در نظر گرفتن میدان موج غیرخطی، مانور کشتی را پیش بینی کنند [۸]. آنها با استفاده از الگوریتم انتشار به عقب^۳ در شبکه های عصبی حرکات کشتی را شبیه سازی کردند و به منظور ارزیابی شبکه را با مقادیر دیگری از زاویه سکان بررسی کردند و نتایج نشان دهنده اعتبار دقت پیش بینی می باشند. اسکتنی^۴ و همکاران در سال ۲۰۰۵ یک روش تطبیقی بازگشتی بر اساس یک مدل پارامتریک غیرخطی برای توصیف دینامیک شناور توسعه دادند [۹]. طبق دسته بندی آنها مسئله مانور شناور شامل دوبخش است، بخش اول هندسی است و به نوعی سیستم را وادار می کند که مسیر مشخصی را طی کند و بخش دوم برقرار ساختن رفتار دینامیکی مورد نظر در طی مسیر طراحی شده است. آنها در این تحقیق ابتدا بخش هندسی را مورد بررسی قرار دادند سپس ارتباطی میان بخش هندسی و دینامیکی برقرار کردند. پس از انجام فرآیند طراحی تست های متعدد تجربی بر روی شناور مدل در آزمایشگاه انجام شده.

فرامین^۵، گودرزی و مالکی در سال ۲۰۱۹ به بررسی طراحی کنترل سرعت و فرمان برای مانور یک شناور سطحی بدون سرنشین (USV) پرداختند [۱۰]. مدل مورد بررسی آنها یک مدل ۴ درجه آزادی و غیرخطی از نوع چند ورودی و چند خروجی (MIMO) به همراه یک کنترلر تطبیقی مبتنی بر تحلیل لیاپانوف^۶ است که به منظور دنبال کردن سرعت مدنظر و تخمین پارامتر های نامعلوم برای حرکت سرج^۷ طراحی شده است. نتایج مربوط به شبیه سازی برای دنبال کردن مسیرها و مانورهای مختلف مناسب و رضایت بخش بوده و درمقایسه با کنترلر PID برتری دارد.

³ Back propagation

⁴ Skjetne

⁵ Faramin

⁶ Lyapunov

⁷ Surge

¹ Computational fluid dynamics

² Feed forward

جانگ^۸ و همکاران در سال ۱۹۹۹ به بررسی بکارگیری تئوری کنترل مقاوم در مانور شناورها پرداختند [۱۱]. تئوری کنترل مقاوم بکار رفته به همراه عدم قطعیت های مدل مانند تغییرات سرعت و اغتشاشاتی مانند امواج می باشند. به منظور فرمول بندی عدم قطعیت ها برای تغییرات پارامترهای مدل از زمانبندی افزایش سرعت استفاده شده است. حذف اغتشاش و همچنین حد اشباع سروو سکان در الزامات عملکرد در نظر گرفته شده است. نتایج تحقیق نشان دهنده این است که کنترل مقاوم پایداری و عملکرد بهتری نسبت به کنترلر های کلاسیک معمولی دارند.

لوک^۹ و همکاران در سال ۲۰۱۱ به شناسایی مدل یک زیرسطحی خودران (AUV) با استفاده از فیلتر کالمن و رویکرد برآورد حداکثر احتمال (به منظور رسیدن به یک مدل نامی با دقت بیشتر) پرداختند [۱۲]. باوجود تلاش برای مدلسازی وسیله، عدم قطعیت هایی در پارامترها به علت برخی دینامیک های پیچیده ظاهر می شوند و چون مدل کردن آنها سخت است از آنها صرف نظر شده است. نتایج کنترل مقاوم در راستای yaw، sway، با فرض اغتشاشات و نویز ها که به کمک شبیه سازی انجام شده، ارائه شده است.

حاصل طلب و همکارش در سال ۲۰۱۹، یک روش مبتنی بر کنترل تطبیقی^{۱۰} برای کنترل حرکت و تعقیب مسیر یک شناور خودران با اتخاذ شبکه های عصبی پیشنهاد کردند که شبکه های عصبی برای تخمین دینامیک پروانه و مدیریت عدم قطعیت های هیدرودینامیکی بکار می روند [۱۳]. با در نظر گرفتن اینکه مدل مانور شناور مشابه مدل غیرخطی غیروابسته است، کنترل تطبیقی پیشنهادی به منظور تخمین تاثیر غیرخطی تابع ورودی که در اینجا دینامیک پروانه و پیشران ها است طراحی شده. آنها از روشی مبتنی بر لیاپانوف برای صحت سنجی الگوریتم کنترلی طراحی شده استفاده کردند. همچنین به منظور ارزیابی عملکرد روش، چندین تست تجربی از جمله شبیه سازی تعقیب مسیر در بندر روتردام انجام شده است. در مباحث مربوط به کنترل آنلاین سرعت الگوریتم های کنترلی اهمیت بالایی دارد، چرا که باید بطور همزمان شناسایی سیستم و کنترل انجام شود. بدلیل اینکه معمولاً استفاده از شبکه های عصبی با توجه به حجم زیاد تخمین پارامترها زمانبر است، برخی زمان ها استفاده از آنها مناسب روش های کنترل آنلاین نمی باشد.

کهوچی^{۱۱} و همکاران در سال ۲۰۱۳ کنترل تطبیقی برای دینامیک شناور در معرض عدم قطعیت ها ارائه کردند و سعی کردند از کاهش کارایی سیستم تحت تاثیر شرایط محیطی اجتناب شود [۱۴]. قوانین کنترل تطبیقی با یک طرح کنترلی

شامل یک کنترلر درجه ۲ خطی (LQ) و یک جبران کننده^{۱۲} مبتنی بر روش ریکاتی^{۱۳} ترکیب شده اند. نتایج طرح آنها نشان می دهد که سیستم کنترل تطبیقی مورد نظر سیگنال نامحدود تولید نمی کند و سیستم پایدار باقی می ماند. همچنین آنها چندین سناریو مانور کشتی برای تابید اثر بخشی رویکردشان شبیه سازی کردند. پرا^{۱۴} و همکاران در سال ۲۰۱۳ با تمرکز بر روش کنترل مبتنی بر لیاپانوف و هورویتز^{۱۵} و کنترلر PID طراحی کنترلر سیستم غیرخطی هدایت شناور پرداختند [۱۵]. آنها یک مدل نوموتو^{۱۶} مرتبه دوم با ویژگی های مانورپذیری غیرخطی به عنوان مدل ریاضی فرمان کشتی در نظر گرفتند. به صورت عمده فرآیند طراحی کنترلر برای سیستم غیرخطی فرمان شناور تحت تاثیر عوامل غیرخطی مانند زاویه سکان، سرعت سکان و زاویه حرکت شناور است، بنابراین آنها به منظور ساده سازی سیستم غیرخطی فرمان شناور، خطی سازی ورودی-خروجی^{۱۷} را پیشنهاد کردند. در طی این فرآیند سیستم به یک سیستم با دینامیک خطی و یک سیستم با دینامیک داخلی تقسیم می شود و شرایط دینامیک داخلی برای بررسی پایداری کلی سیستم فرمان شناور تحلیل می شود. در نهایت آنها الگوریتم های کنترلی پیشنهادی برای سیستم هدایت شناور را شبیه سازی کردند و نتایج موفقیت آمیز برای مانور های حفظ مسیر و تغییر مسیر را ارائه کردند. آنها در این تحقیق به بررسی شرایط هدایت غیرخطی پایدار پرداختند و بررسی شرایط ناپایدار را به تحقیقات آینده موکول کردند. ژنگ^{۱۸} و همکاران در سال ۲۰۱۹، یک الگوریتم شناسایی آنلاین مبتنی بر شبکه های عصبی برای شناسایی مدل غیر خطی یک شناور کانتینربر KCS پیشنهاد دادند [۱۶]. آنها از طریق چند سری تست Free-running که شامل دور زدن، تست زیگزاگ و تست توقف بوده است، داده های مورد نیاز برای انجام فرایند شناسایی را تهیه کردند و به کمک شبکه عصبی و به صورت آنلاین شناسایی پارامتریک سیستم انجام دادند. اگرچه در پژوهش های مورد بررسی از شبکه عصبی پیشخور برای مدلسازی رفتار شناورها استفاده شده است اما استفاده از شبکه عصبی مصنوعی بازگشتی (RNN^{۱۹}) بدلیل وجود پسخور در ساختار می تواند به صورت دقیق تر رفتار دینامیکی شناور را مدلسازی کند. در این پژوهش از یک شبکه بازگشتی برای استخراج مدل دینامیک حرکت سمتی شناور و انجام شبیه سازی های مربوطه استفاده شده است.

¹² Compensator

¹³ Riccati

¹⁴ Perera

¹⁵ Hurwitz

¹⁶ Nomoto

¹⁷ Input-Output Linearisation

¹⁸ Zheng

¹⁹ Recurrent Neural Network


⁸ Juang

⁹ Luque

¹⁰ Adaptive Control

¹¹ Kahveci

برای تعیین تعداد سلول های شبکه عصبی قانون ثابت و مشخصی وجود ندارد و با سعی و خطا بگونه ای تعیین شود که بتواند سیستم را بخوبی شبیه سازی کند و در عین حال از کمترین تعداد سلول ممکن تشکیل شده باشد. ساختار در نظر گرفته شده در این پروژه دارای ۲ لایه سلول می باشد که لایه اول متشکل از ۴ سلول و لایه دوم یک سلول عصبی دارد. برای تقسیم ورودی ها نیز دو گره قبل از لایه اول در نظر گرفته شده است. خروجی شبکه نرخ زاویه سمت است. همچنین در آموزش دینامیک شبکه نرخ زاویه سمت بعنوان فیدبک از طریق بازگشت کننده^{۲۱} RC1 به سیستم داده می شود، شماتیک شبکه عصبی در شکل ۲ نشان داده شده است.



شکل ۲-ساختار در نظر گرفته شده برای شبکه عصبی

۴- روش آموزش شبکه عصبی

منظور از آموزش شبکه عصبی تعیین وزن های سیناپس ها و مقدار بایاس هر سلول به گونه ای که خروجی شبکه با خروجی سیستم واقعی، به ازای ورودی یکسان، همخوانی داشته باشد. در نهایت با تعیین وزن ها و بایاس ها یک مدل از سیستم مبتنی بر شبکه عصبی تهیه می شود که می تواند در شبیه سازی ها مورد استفاده قرار گیرد.


برای آموزش شبکه عصبی از روش انتشار خطا به عقب^{۲۲} استفاده می شود. برای محاسبه ورودی هر عصب از تابع انتشار^{۲۳} x_i مطابق رابطه (۱۰) و جهت محاسبه خروجی از تابع فعالسازی y_i استفاده می شود. از تابع سیگموید بدلیل قابلیت موجود در مشتق گیری آن بعنوان تابع فعالسازی^{۲۴} استفاده می شود. باتوجه به اینکه خروجی تابع سیگموید بین ۰ و ۱ است و r مقادیر منفی هم دارند از تابع سیگمویدی که به اندازه منفی ۰/۵ انتقال داده شده مطابق رابطه (۱۱) استفاده می شود.

۲- سیستم مورد بررسی

سیستم مورد بررسی در این پروژه یک شناورمدل با فرم بدنه KCS به مشخصات ارائه شده در جدول ۱ می باشد. باتوجه به عدم امکان دسترسی به داده های تجربی مدل دینامیکی شناور در محیط سیمولینک متلب تهیه و داده های مورد نیاز برای آموزش شبکه از آن استخراج می شود. ورودی سیستم زاویه سکان است که بین $\pm 35^\circ$ تغییر می کند و خروجی مدنظر نرخ تغییرات یاو^{۲۰} یا همان r می باشد. برای آشنایی اولیه با رفتار سیستم، ورودی زیگزاگ مطابق شکل ۱ و به مدل دینامیکی داده شده و خروجی سیستم ثبت شده است. پریود و دامنه ورودی داده شده به سیستم به ترتیب ۱۰۰ ثانیه و 35° درجه است.

جدول ۱- مشخصات شناور مدل

طول	۷ متر
عرض	۱.۲۷ متر
آبخور	۴۶ سانتی متر
جابه جایی	۳.۲۷ مترمکعب



شکل ۱- اعمال به ورودی زیگزاگ با پریود ۱۰۰ ثانیه جهت تهیه داده های مورد نیاز برای آموزش شبکه

$$x_i = \sum_{j=1}^n W_{ij} \cdot y_j + \theta_j \quad (10)$$

$$y_i = \frac{1}{1 + e^{-x_i}} - 0.5 \quad (11)$$

۳- ساختار شبکه عصبی مورد استفاده

²¹ Recurrent

²² Error Back Propagation

²³ Propagation Function

²⁴ Activation Function

²⁰ Yaw Rate

در نظر گرفته شده است. پس از آموزش استاتیک شبکه مقادیر وزن و بایاس شبکه در جدول ۲ و جدول ۳ ارائه شده‌اند.


جدول ۲-مقادیر بایاس پس از آموزش استاتیک

مقدار	بایاس
0.1288	θ_1
0.3610	θ_2
-0.0779	θ_3
0.0968	θ_4
-0.2473	θ_5

جدول ۳-مقادیر وزن های شبکه پس از آموزش استاتیک

مقدار	ضریب وزنی سیناپس
2.8739	W_{11}
1.7713	W_{12}
1.7259	W_{13}
1.7572	W_{14}
-0.4728	W_{21}
0.2533	W_{22}
0.5535	W_{23}
0.1451	W_{24}
2.9128	W_{15}
1.5893	W_{25}
1.3445	W_{35}
1.6483	W_{45}

نمودار مقایسه ای خروجی حاصل از شبکه و شبیه سازی در شکل ۳ داده شده است. همانگونه که در نمودار قابل مشاهده است، تطابق بسیار خوبی میان داده های خروجی شبکه و داده های تست در آموزش استاتیک وجود دارد اما باید در نظر داشت که آموزش استاتیک صرفا به منظور تنظیم اولیه وزن ها و بایاس ها برای شروع آموزش دینامیک است و چون در آن بیش برآزش^{۲۶} رخ داده است امکان پیش بینی رفتار کلی سیستم را نخواهد داشت.



شکل ۳-مقایسه خروجی شبکه و خروجی شبیه سازی پس از آموزش استاتیک شبکه (درصد خطای RMS : 2.2%)

تابع سیگموئید محدوده غیرخطی مناسبی دارد و چون نرخ Yaw مقادیر کمتر از یک میباشند ، با خروجی حاصل از این تابع همخوانی دارد. در روش انتشار خطا به عقب ، به کمک قانون دلتا خطا در هر مرحله محاسبه و وزن ها توسط آن بروزرسانی می شوند.

$$E = y_i^d - y_i \quad (12)$$

در رابطه (۱۲) ، y_i^d خروجی مطلوب و y_i خروجی شبکه عصبی می باشد. بایستی مقادیر وزن ها به گونه ای انتخاب شوند که تابع خطا کمترین مقدار را داشته باشد و خروجی شبکه با خروجی مطلوب مشابه شود. مقدار دلتا برای لایه انتهایی از رابطه (۱۳) بدست می آید .

$$\delta_i = f'(x_i)(y_i^d - y_i) \quad (13)$$

همچنین مقدار دلتا برای لایه های قبلی از رابطه (۱۴) بدست می آید.

$$\delta_i = f'(x_i) \sum \delta_k W_{ik} \quad (14)$$

که k مربوط به لایه بعدی است. مشتق تابع سیگموئید $y_i = \frac{1}{1+e^{-x_i}}$ بصورت رابطه (۱۵) محاسبه می شود.

$$f'(x_i) = f(x_i)(1 - f(x_i)) \quad (15)$$

ضرایب وزنی و بایاس ها در هر مرحله به کمک روابط (۱۶) و (۱۷) بروزرسانی می شوند.


$$\begin{aligned} \Delta W_{ji}(n) &= \eta y_j \delta_i + \alpha \Delta W_{ji}(n-1) \\ W_{ji}^{new} &= W_{ji}^{old} + \Delta W_{ji} \end{aligned} \quad (16)$$

$$\begin{aligned} \Delta \theta_{ji}(n) &= \eta \delta_i + \alpha \Delta \theta_{ji}(n-1) \\ \theta_{ji}^{new} &= \theta_{ji}^{old} + \Delta \theta_{ji} \end{aligned} \quad (17)$$

در روابط (۱۶) و (۱۷) شماره اپوک^{۲۵} است و η نرخ آموزش و α مومنتوم آموزش می باشد.

۵- آموزش استاتیک شبکه عصبی


مرحله اول آموزش شبکه عصبی بصورت استاتیک است. در مرحله استاتیک بازگشت کننده قطع شده و شبکه در ۵۰۰۰ اپوک بصورت استاتیک و با استفاده از داده های زاویه سکان δ و نرخ Yaw حاصل از شبیه سازی سیمولینک آموزش داده میشود. در این مرحله از آموزش نرخ مومنتوم و نرخ آموزش هر دو برابر 0.15




شکل ۴-مقایسه خروجی شبکه و خروجی شبیه سازی پس از آموزش دینامیک شبکه (درصد خطای RMS : 10.9%)

۷- ارزیابی عملکرد شبکه با ورودی متفاوت

برای بررسی میزان کارایی شبکه برای ورودی های متفاوت از داده های آموزش، از ورودی های سینوسی و دندان اره ای استفاده می شود. ابتدا از ورودی زیگزاگ با پریود ۲۰ ثانیه مطابق شکل ۵ استفاده می شود تا میزان کارایی شبکه در فرکانس های متفاوت از فرکانس داده های آموزش بررسی شود. نتایج حاصل شده در نمودار شکل ۶ نشان می دهد که شبکه آموزش داده شده به خوبی توانایی پیش بینی رفتار را در ورودی زیگزاگ با فرکانس متفاوت را دارد.



شکل ۵- پاسخ سیستم اصلی به ورودی زیگزاگ با پریود ۲۰ ثانیه



شکل ۶- پاسخ شبکه عصبی به ورودی زیگزاگ فرکانس بالا و مقایسه با پاسخ سیستم اصلی (درصد خطای RMS : 16.7%)

۶- آموزش دینامیک شبکه عصبی

باتوجه به اینکه سیستم مدنظر در واقعیت یک سیستم وابسته به زمان و دینامیک است، مطابق شکل ۳ آموزش استاتیک اگر چه به خوبی نتایج حاصل از شبکه عصبی را با نتایج شبیه سازی منطبق می کند اما برای پیش بینی بهتر رفتار سیستم واقعی در شرایط مختلف بایستی سیستم به صورت دینامیک آموزش داده شود. در واقع آموزش استاتیک برای جهت دادن به روند تعیین وزن ها و جلوگیری از عدم همگرایی فرایند تکرار است. تعداد مرحله آموزش دینامیک ۱۰۰۰۰ و مقادیر نرخ مومنتوم ۰/۰۱ و نرخ آموزش ۰/۰۰۵ تنظیم می شوند. لازم به ذکر است که تعیین مقادیر نرخ مومنتوم و نرخ آموزش قانون مشخصی ندارد و بر اساس آزمون خطا برای بهبود پاسخ ها بگونه ای تعیین می گردد که علاوه بر جلوگیری از واگرایی، از طولانی شدن فرایند آموزش نیز جلوگیری نماید. در مرحله آموزش دینامیک بازگشت کننده RC1 که در شکل ۲ نمایش داده شده، وصل می گردد و سرعت بعنوان فیدبک به سیستم داده می شود. ضرایب وزنی و مقادیر بایاس پس از ۱۰۰۰۰ مرحله آموزش دینامیک در جدول ۴ و جدول ۵ ارائه شده اند.


جدول ۴-مقادیر بایاس پس از آموزش دینامیک

مقدار	بایاس
θ_1	0.2661
θ_2	0.1173
θ_3	0.9351
θ_4	0.3539
θ_5	-0.4162

جدول ۵-مقادیر وزن های شبکه پس از آموزش استاتیک


مقدار	ضریب وزنی سیناپس
W_{11}	2.1513
W_{12}	2.9595
W_{13}	0.5040
W_{14}	1.2401
W_{21}	-0.0350
W_{22}	-0.0129
W_{23}	0.2225
W_{24}	0.1689
W_{15}	2.0078
W_{25}	2.8584
W_{35}	0.4374
W_{45}	1.2145

نمودار مقایسه ای خروجی حاصل از شبکه و شبیه سازی پس از آموزش دینامیک در شکل ۴ نشان داده شده است.




شکل ۹- پاسخ سیستم به ورودی دندان اره ای با پریود ۱۰۰ ثانیه


در این مرحله ارزیابی از ورودی سینوسی با پریود مشابه ورودی زیگزاگ یعنی ۱۰۰ ثانیه مطابق شکل ۷ استفاده می‌شود تا اثر تفاوت نوع ورودی بر عملکرد شبکه نیز مورد ارزیابی قرار گیرد. خروجی سیستم اصلی گرفته شده و با خروجی شبکه مقایسه و میزان خطا محاسبه شده است و براساس نمودارهای شکل ۸ نتیجه می‌شود که شبکه نسبت به ورودی متفاوت از آموزش نیز پاسخ مناسبی می‌دهد دلیل این امر غنای ورودی زیگزاگ است که در برگزیده طیف وسیعی از ورودی های سینوسی با فرکانس و دامنه متفاوت است.



شکل ۷- پاسخ سیستم اصلی به ورودی سینوسی با پریود ۱۰۰ ثانیه



شکل ۱۰- پاسخ شبکه عصبی به ورودی دندان اره ای با پریود ۱۰۰ ثانیه (درصد خطای RMS : 29.4%)



شکل ۸- پاسخ شبکه عصبی به ورودی سینوسی با پریود ۱۰۰ ثانیه (درصد خطای RMS : 17%)

۸- نتیجه گیری

در این پژوهش یک شبکه عصبی بازگشتی با استفاده از داده‌های بدست آمده از شبیه سازی شناور آموزش داده شد. هدف مدلسازی ارتباط دینامیکی میان زاویه سکان و نرخ زاویه سمت بوده که همانطور که از نمودار ها مشاهده می‌شود و باتوجه به مقادیر خطای میان خروجی شبکه عصبی و سیستم اصلی، شبکه به خوبی آموزش داده شده است و قابلیت پیش بینی برای انواع دیگر ورودی ها را دارد. گاهی اوقات اگرچه آموزش شبکه با دقت انجام می‌شود اما به دلایلی مانند نوع سیستم و رفتار آن ممکن است قابلیت شبیه سازی ورودی هایی غیر از ورودی آموزش داده شده را نداشته باشد، در این حالت باید برای هر نوع ورودی (سینوسی ، زیگزاگ ، دندان اره ای و ...) وزن های مجزا بدست آورد و برای هر ورودی استفاده نمود. انتخاب ورودی مناسب برای تحریک یک سیستم و جمع آوری داده های مورد نیاز آموزش شبکه اهمیت بالایی دارد همانطور که مشاهده شد استفاده از سیگنال زیگزاگ باتوجه به اینکه طبق بسط فوریه قابل بازنویسی به سیگنال های سینوسی با فرکانس و دامنه متفاوت است، باعث می‌شود تا پس از

در ادامه از ورودی دندان اره ای با پریود مشابه ورودی زیگزاگ یعنی ۱۰۰ ثانیه مطابق شکل ۹ استفاده می‌شود. نتایج ارزیابی خروجی سیستم اصلی گرفته شده و با خروجی شبکه در نمودارهای شکل ۱۰ نمایش داده شده اند و نشان می‌دهند که شبکه در پیش بینی رفتار ورودی دندان اره ای نسبت به ورودی زیگزاگ و سینوسی دقت کمتری دارد.

- 10- Faramin, M., R. Goudarzi, and A. Maleki, *Track-keeping observer-based robust adaptive control of an unmanned surface vessel by applying a 4-DOF maneuvering model*. Ocean Engineering, 2019. 183: p. 11-23.
<https://doi.org/10.1016/j.oceaneng.2019.04.051>
- 11- Juang, J.Y. and B. Chang. *Robust control theory applied to ship maneuvering*. in Proceedings of the 38th IEEE Conference on Decision and Control (Cat. No. 99CH36304). 1999. IEEE.
<https://doi.org/10.1109/CDC.1999.831244>
- 12- Luque, J.C.C. and D.C. Donha, *Auv identification and robust control*. IFAC Proceedings Volumes, 2011. 44(1): p. 14735-14741.
<https://doi.org/10.3182/20110828-6-IT-1002.03554>
- 13- Haseltalab, A. and R.R. Negenborn, *Adaptive control for autonomous ships with uncertain model and unknown propeller dynamics*. Control Engineering Practice, 2019. 91: p. 104116.
<https://doi.org/10.1016/j.conengprac.2019.104116>
- 14- Kahveci, N.E. and P.A. Ioannou, *Adaptive steering control for uncertain ship dynamics and stability analysis*. Automatica, 2013. 49(3): p. 685-697.
<https://doi.org/10.1016/j.automatica.2012.11.026>
- 15- Perera, L.P. and C.G. Soares, *Lyapunov and Hurwitz based controls for input-output linearisation applied to nonlinear vessel steering*. Ocean Engineering, 2013. 66: p. 58-68.
<https://doi.org/10.1016/j.oceaneng.2013.04.002>
- 16- Zheng, J., Y. Li, and F. Meng. *Online Identification Method of Nonlinear Ship Motion Mathematical Models from Free-Running Tests*. in 2019 IEEE 28th International Symposium on Industrial Electronics (ISIE). 2019. IEEE.
<https://doi.org/10.1109/ISIE.2019.8781124>

آموزش مدل حاصل شده توانایی خوبی در تقریب رفتار سایر ورودی‌ها نیز داشته باشد. مدل بدست آمده می‌تواند بخشی از یک شبیه ساز برای کاربردهایی همچون آموزش خدمه شناور، طراحی سیستم کنترل و ناوبری مناسب باشد. در گام‌های بعدی می‌توان این مدل یک درجه آزادی را به مدل مرسوم و کاربردی‌تر با سه درجه آزادی توسعه داد و مانور یک شناور سطحی را به‌طور کامل بررسی نمود.

۹- مراجع

- 1- Liu, Z., Zhang, Y., Yu, X., & Yuan, C. (2016). *Unmanned surface vehicles: An overview of developments and challenges*. Annual Reviews in Control, 41, 71-93.
<https://doi.org/10.1016/j.arcontrol.2016.04.018>
- 2- Roberts, G. N., & Sutton, R. (Eds.). (2006). *Advances in unmanned marine vehicles* (Vol. 69). Iet.
<https://doi.org/10.1049/PBCE069E>
- 3- Manley, J. E. (2008, September). *Unmanned surface vehicles, 15 years of development*. In OCEANS 2008 (pp. 1-4). Ieee.
<https://doi.org/10.1109/OCEANS.2008.5152052>
- 4- Fossen, T. I. (2011). *Handbook of marine craft hydrodynamics and motion control*. John Wiley & Sons.
<https://doi.org/10.1002/9781119994138>
- 5- Zhang, Z. R., Hui, L., & Feng, Z. H. A. O. (2006). *Application of CFD in ship engineering design practice and ship hydrodynamics*. Journal of Hydrodynamics, Ser. B, 18(3), 315-322.
[https://doi.org/10.1016/S1001-6058\(06\)60072-3](https://doi.org/10.1016/S1001-6058(06)60072-3)
- 6- Luo, W. and Z. Zhang, *Modeling of ship maneuvering motion using neural networks*. Journal of Marine Science and Application, 2016. 15(4): p. 426-432.
<https://doi.org/10.1007/s11804-016-1380-8>
<https://doi.org/10.1007/s11804-016-1380-8>
- 7- Xing, Z. and L. McCue, *Modeling ship equations of roll motion using neural networks*. Naval Engineers Journal, 2010. 122(3): p. 49-60.
<https://doi.org/10.1111/j.1559-3584.2010.00241.x>
- 8- Zăgan, R., M.G. Chițu, and E. Manea, *Ship Manoeuvrability Prediction Using Neural Networks Analysis*. Advanced Materials Research, 2014. 1036: p. 946-951.
<https://doi.org/10.4028/www.scientific.net/AMR.1036.946>
- 9- Skjetne, R., T.I. Fossen, and P.V. Kokotović, *Adaptive maneuvering, with experiments, for a model ship in a marine control laboratory*. Automatica, 2005. 41(2): p. 289-298.