

کنترل باریکه الکترون حلقه انبارش شتابگر ۲.۰ ELETTRA با استفاده از یادگیری ماشین

محمدصادق یزدانی^۱، سیدفرهاد مسعودی^{۱*}، جواد رحیقی^۲، سارا داستان^۳

۱. دانشکده فیزیک، دانشگاه صنعتی خواجه نصیرالدین طوسی، کدپستی: ۱۵۸۷۵۴۴۱۶، تهران - ایران
۲. پژوهشکده ذرات و شتابگرها، پژوهشگاه دانش‌های بنیادی (IPM)، صندوق پستی: ۱۹۳۹۵-۵۷۴۶، تهران - ایران
۳. سنکروترون الترا (Elettra Sincrotrone Trieste)، تریست - ایتالیا

*Email: masoudi@kntu.ac.ir

مقاله پژوهشی

تاریخ دریافت مقاله: ۱۴۰۳/۰۴/۱۱ تاریخ بازنگری مقاله: ۱۴۰۳/۰۷/۲۸ تاریخ پذیرش مقاله: ۱۴۰۳/۰۸/۰۵

چکیده

در دهه اخیر، گام‌های قابل توجهی در پیشرفت فناوری شتابگرهای سنکروترون الکترون (چشمه نور)، به‌ویژه در بهبود کیفیت باریکه، برداشته شده است. این شتابگرها به طور دوره‌ای بازطراحی شده و ارتقا می‌یابند تا نیازهای علمی در حال تکامل را برآورده کنند. یک جنبه حیاتی طراحی آن‌ها کنترل دقیق مدار الکترون و تصحیح هرگونه خطا برای دستیابی به یک باریکه الکترون پایدار و در نتیجه باریکه فوتون پایدار با درخشندگی زیاد است. یکی از روش‌های مورد توجه در این زمینه، استفاده از شبکه‌های عصبی برای تصحیح موقعیت باریکه الکترونی در حلقه انبارش است؛ فرایندی که معمولاً به‌عنوان کنترل مداری شناخته می‌شود. در این مطالعه، برای اولین بار یک مدل مبتنی بر معماری شبکه عصبی پیچشی برای مدیریت حلقه انبارش ۲.۰ ELETTRA (شتابگر چشمه نور در ایتالیا) آموزش داده شده است. عملکرد این مدل که مبتنی بر استفاده از فنون یادگیری ماشینی است، حدود ۶ درصد بهتر از روش ISVD است، درحالی‌که صحت عملکرد آن نسبت به داده‌های دنیای واقعی به سختی کاهش می‌یابد.

کلیدواژه‌ها: یادگیری ماشینی، شبکه عصبی پیچشی، کنترل‌کننده عصبی مصنوعی، کنترل مدار، حلقه انبارش ۲.۰ ELETTRA

Electron beam control in the storage ring of the ELETTRA 2.0 accelerator using machine learning

M.S. Yazdani¹, S.F. Masoudi^{1*}, J. Rahighi², S. Dastan³

1. Department of Physics, K.N. Toosi University of Technology, Postal Code: 158754416, Tehran – Iran

2. School of Particles and Accelerators, Institute for Research in Fundamental Sciences (IPM), PO Box: 19395-5746, Tehran, Iran

3. Elettra - Sincrotrone Trieste, Trieste - Italy

Research Article

Received: 01.07.2024,

Revised: 19.10.2024,

Accepted: 26.10.2024

Abstract

In recent years, the advancement of electron synchrotron light sources has been crucial for synchrotron radiation users. Improving electron beam qualities, such as stability and intensity, has been key to generating high-brightness photon beams. To achieve a brighter photon beam, electron synchrotron accelerators have been undergoing significant design changes. A critical aspect of their design is precise control of particle trajectories and correction of errors to achieve a stable electron beam and, consequently, a high-intensity photon beam. One interesting approach in this field is the use of neural networks to correct the electron beam position in the storage ring, a process known as beam control. In this study, a convolutional neural network model has been developed for the first time to control the ELETTRA 2.0 storage ring, a synchrotron light source in Italy. The performance of this model, based on machine learning techniques, is approximately 6% better than the ISVD method, while also demonstrating high robustness to real-world data.

Keywords: Machine learning, Convolutional neural network, Artificial neural controller, Orbit control, Elettra 2.0 storage ring



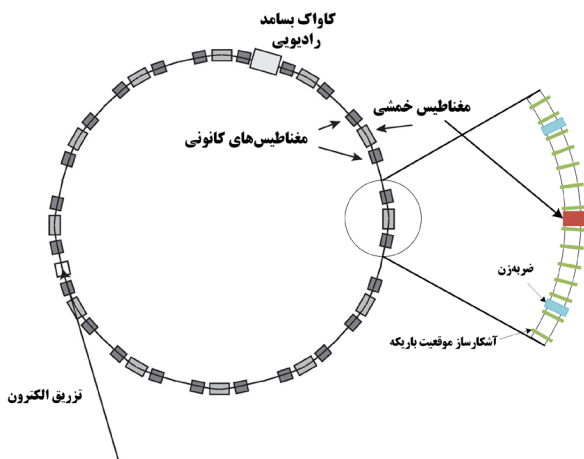
۱. مقدمه

افزایش کیفیت تابش سنکروترون وجود دارد [۴-۹]. یادگیری ماشینی می‌تواند به عنوان یک ابزار توانمند برای این منظور عمل کند زیرا می‌تواند از داده‌ها یاد بگیرد و با محیط‌های پیچیده و پویا سازگار شود [۱۰]. یادگیری ماشینی همچنین مزایایی را نسبت به روش‌های کنترل سنتی مانند استقلال از مدل^۸، بهینه‌سازی مبتنی بر داده، یادگیری برخط و خودبهبودی ارائه می‌دهد [۱].

۲. تصحیح مدار بسته در ۲.۰ ELETTRA

در این تحقیق، یک کاربرد یادگیری ماشینی برای کنترل مدار باریکه الکترونی در حلقه انبارش چشمه نور سنکروترون ۲.۰ ELETTRA با گسیلندگی کم در حال ساخت در تریسته^۹ ایتالیا است، ارائه شده است [۱۱]. این پژوهش بر پیش‌بینی مقدار دامنه «تصحیح‌گر مطلق باریکه»^{۱۰} مداری متمرکز شده است. این پیش‌بینی براساس داده‌های BPM انجام می‌شود. همچنین چالش‌ها و فرصت‌های به‌کارگیری این روش، برای پژوهش‌های آتی در این زمینه نیز بررسی شده است.

مطابق شکل ۱ طرح شبکه ۲.۰ ELETTRA از ۱۲ سلول تشکیل شده که هر سلول شامل تجهیزات مختلفی است. به طور خاص می‌توان به مغناطیس خمشی (دو نوع دوقطبی بلند با زاویه خمش ۳/۶ درجه و طول ۶۴ سانتی‌متر و ۴ دوقطبی با زاویه خمش ۶/۵ درجه و طول ۸۰ سانتی‌متر) اشاره کرد. این شبکه دارای گسیلندگی طبیعی ۲۱۲ پیکومتر رادیان برای انرژی ۲/۴ گیگاالکترون‌ولت و محیط ۲۵۹/۲ متر است [۱۲].



شکل ۱. یک سلول در شبکه شتابگر به همراه برخی اجزای آن به صورت نمونه.

یادگیری ماشینی^۱، به‌عنوان زیرمجموعه‌ای از هوش مصنوعی، رایانه‌ها را قادر می‌سازد تا با استفاده از داده‌ها، آموزش ببینند و در نتیجه عملکرد خود را بدون نیاز به کدنویسی صریح افزایش دهند. این روش کاربردهای گسترده‌ای در زمینه‌های مختلف از جمله بینایی ماشینی^۲، پردازش زبان طبیعی^۳، بیوانفورماتیک و رباتیک پیدا کرده است. یکی از کاربردهای نوظهور یادگیری ماشینی در کنترل باریکه الکترونی در چشمه‌های نور سنکروترون است، تأسیساتی که تابش الکترومغناطیسی با شدت و کیفیت زیاد را در مقیاس بزرگ برای تحقیقات علمی تولید می‌کنند [۱].

در چشمه نور باریکه الکترونی با انرژی ثابت (در محدوده چند گیگاالکترون‌ولت) برای مدت طولانی (حدود ۲۴ تا ۴۸ ساعت) در حلقه انبارش ذخیره می‌شود. هنگامی که باریکه الکترونی از دستگاه‌های مغناطیسی مانند الکترومغناطیس‌های دوقطبی^۴، لرزاننده‌ها^۵ و موج‌واره‌سازها^۶ عبور می‌کند، تابش سنکروترون ساطع می‌کند. این تابش می‌تواند دارای ویژگی‌های مطلوبی مانند درخشندگی زیاد، گسیلندگی کم، همدوسی زیاد و قطبیده باشد [۲]. کیفیت باریکه به عوامل مختلفی بستگی دارد که از جمله می‌توان به قرارگیری عرضی باریکه تا حد امکان روی نقطه مرجع (صفر)، کیفیت و دقت در نصب تجهیزات کنترلی باریکه مانند تجهیزات الکترومغناطیسی و آشکارسازهای موقعیت باریکه (BPM)^۷ اشاره کرد. در نهایت باریکه الکترون با کیفیت می‌تواند تابش سنکروترونی مطلوبی را به دست دهد.

حفظ پایداری و کیفیت باریکه الکترونی و در حقیقت، تابش سنکروترون در حلقه انبارش چالش‌های متعددی را به همراه دارد [۳]. علاوه بر این، اختلالات ناشی از عوامل خارجی اطراف حلقه انبارش، مانند ارتعاشات زمین، افت‌وخیز جریان منبع تغذیه الکترومغناطیس و تغییرات دما، می‌توانند بر پایداری باریکه تأثیر بگذارند. این عوامل ممکن است عملکرد حلقه انبارش را کاهش داده و استفاده بالقوه آن را برای تحقیقات علمی محدود کنند. در نتیجه، نیازمندی‌هایی برای روش‌های کنترل مؤثر و دقیق برای بهینه‌سازی عملکرد حلقه انبارش و

1. Machine Learning (ML)
2. Computer Vision
3. Natural Language Processing
4. Bending Magnet
5. Undulator
6. Wiggler
7. Beam Position Monitor (BPM)

8. Model-Independence

9. Trieste

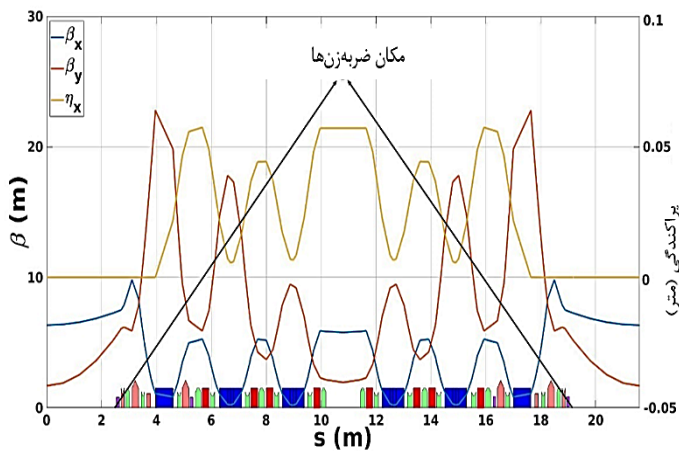
10. Pure Corrector



ایجاد پراکندگی^۷ در باریکه الکترونی می‌شود. گرچه چهارقطبی‌ها و فضاها خالی در شبکه منبع ایجاد پراکندگی نیستند، اما بر تابع پراکندگی باریکه تأثیر گذارند. تابع پراکندگی، جابه‌جایی مدار مرجع باریکه به دلیل تغییر تکانه آن را توصیف می‌کند. در واقع، پراکندگی در یک شتابگر ذرات به تغییر مدار بسته ذرات با تکانه‌های مختلف اشاره دارد. این پارامتر وابستگی موقعیت ذرات به انحراف تکانه آن‌ها از تکانه مرجع را توضیح می‌دهد و با استفاده از خصوصیت‌های اجزای شبکه قابل دستیابی است [۱۴].

جدول ۱. تعداد برخی از قطعات هدایت‌گر باریکه در شبکه ELETTRA ۲.۰

تعداد	تجهیز
۱۶۸	BPM
۲۴	تصحیح‌گر مطلق باریکه (ضربه‌زن)
۷۲	مغناطیس‌های دوقطبی
۹۶	مغناطیس‌های چهارقطبی
۲۴۰	مغناطیس‌های شش‌قطبی



شکل ۲. نمونه‌ای از یک سلول در شبکه ELETTRA ۲.۰. پارامترهای توییس در این تصویر نشان داده شده است. خطوط آبی و قرمز به ترتیب توابع بتا در سطوح افقی و عمودی هستند و خط زرد تابع پراکندگی شبکه است. همچنین مستطیل‌های آبی دوقطبی در شبکه، مستطیل‌های قرمز الکترومغناطیس‌های ضد خم، مستطیل‌های صورتی چهارقطبی، مستطیل‌های سبز شش‌قطبی و مستطیل‌های بنفش هشت‌قطبی هستند. موقعیت تصحیح‌گرها در نمودار ارائه شده است.

بر این اساس، طبق جدول ۱، سامانه کنترل مدار ELETTRA ۲.۰ از ۲۴ تصحیح‌گر باریکه (۲ عدد در هر سلول) و ۱۶۸ BPM (۱۴ عدد در هر سلول) استفاده می‌کند که در طول حلقه انبارش توزیع شده‌اند. در ادامه متن، تصحیح‌گر را ضربه‌زن^۱ می‌نامیم. ضربه‌زن‌ها تجهیزات الکترومغناطیس افقی و عمودی هستند که می‌توانند مسیر باریکه الکترونی را با اعمال انحرافات کوچک تنظیم کنند. BPMها ابزارهایی هستند که موقعیت عرضی باریکه الکترونی را با حسگرهای القایی روی الکترودها یا خطوط نواری با دقت میکرومتر اندازه‌گیری می‌کنند. همچنین هر سلول از ۸ چهارقطبی (۴ چهارقطبی کانونی^۲ و ۴ چهارقطبی واکانونی^۳) و ۲۰ شش‌قطبی تشکیل شده است (برخی از شش‌قطبی‌ها دارای سیم‌پیچ‌هایی برای ضربه‌زن‌ها و برخی دیگر برای ایجاد چهارقطبی اریب برای کنترل جفت‌شدگی باریکه هستند). علاوه بر این، ۴ چندقطبی ترکیبی (هشت‌قطبی و تصحیح‌کننده) در هر سلول برای تصحیح رنگینگی^۴ در نظر گرفته شده است که این آرایش در شکل ۲ نشان داده شده است [۱۳]. در فیزیک شتابگرها، اندازه عرضی توزیع ذرات در باریکه الکترونی به عنوان یک معیار مهم مطرح می‌شود. این مقدار، رابطه مستقیم با تابعی دارد که به عنوان تابع بتا^۵ نیز شناخته می‌شود و در هر نقطه در طول حرکت ذرات در شتابگر قابل محاسبه است. تابع بتا دامنه حرکت باریکه است و با اندازه باریکه متناسب است، به این ترتیب هر چه تابع بتا بزرگ‌تر باشد یعنی اندازه باریکه بزرگ‌تر است. این پارامتر جزء پارامترهای توییس^۶ هست که به صورت غیرمستقیم و توسط رابطه ۱ توزیع مکان و تکانه ذرات باریکه را در شتابگرها توصیف می‌کنند.

$$\gamma x^2 + 2\alpha x x' + \beta x'^2 = \epsilon \quad (1)$$

در این رابطه، x مکان، x' زاویه و ϵ گسیلندگی باریکه هستند. α ، β و γ پارامترهای توییس هستند. همچنین انرژی ذرات مختلف در باریکه الکترونی دقیقاً یکسان نیست. این اختلاف انرژی در حضور الکترومغناطیس‌های دوقطبی باعث

1. Kicker
2. Focusing Quadrupole Magnet
3. Defocusing Quadrupole Magnet
4. Chromaticity
5. β (Beta Function)
6. Twiss Parameters

7. Dispersion



مستقیماً از نتایج تجزیه مشتق کرد و درک دینامیک باریکه را افزایش داد. باین حال، قابل توجه است که ISVD ممکن است در مدیریت روابط بسیار غیرخطی با چالش‌هایی مواجه شود و ممکن است وابستگی‌های ظریف در داده‌ها را به اندازه روش‌های یادگیری ماشینی دریافت نکند.

از آنجایی که ۲۰۰ ELETTRA هنوز در مرحله طراحی و ساخت است، از داده‌های شبیه‌سازی به‌عنوان ورودی برای رویه یادگیری ماشینی استفاده می‌کنیم. در اینجا از نرم‌افزار ELEGANT برای شبیه‌سازی باریکه مختل شده و تصحیح آن با روش ISVD استفاده شده است، برای این منظور از هزاران مجموعه ماشینی استفاده شده و طبق جدول ۲ از خطاهای الکترومغناطیس برای ایجاد اختلال در باریکه استفاده شده است [۱۶]. همچنین در پژوهش‌های آتی می‌توان سایر منابع خطا را نیز در شبیه‌سازی در نظر گرفت.

در نرم‌افزار ELEGANT با اعمال خطاهای مفروض، باریکه مختل شده شبیه‌سازی می‌شود و با استفاده از داده‌های به‌دست آمده در طول شبیه‌سازی برای BPM می‌توان موقعیت باریکه مختل شده و همچنین دامنه ضربه‌زن‌ها را در خروجی با قالب مجموعه داده‌های خود توصیفی (SDDS^۴) خواند. در این پژوهش از داده‌های BPM برای باریکه تصحیح نشده به‌عنوان ورودی در یادگیری ماشینی استفاده می‌شود.

جدول ۲. خطای الکترومغناطیس‌ها [۱۷]

نوع خطا	نوع الکترومغناطیس	صفحه واحد	مقدار
هم‌راستایی	چهار و شش قطبی	افقی μm	۲۵
هم‌راستایی	چهار و شش قطبی	عمودی μm	۲۵
هم‌راستایی	دوقطبی	افقی μm	۵۰
هم‌راستایی	دوقطبی	عمودی μm	۵۰
خطای نسبی قدرت	دو، چهار و شش قطبی	-	۰/۰۰۰۳
شیب	چهار و شش قطبی	-	۵۰ μrad
شیب	دوقطبی	-	۱۰۰ μrad

یک رویکرد مرسوم و متداول در تصحیح مدار استفاده از روش «تجزیه مقادیر منفرد تکراری»^۱ است [۱۵]. اما در این پژوهش، از روش‌های یادگیری ماشینی جهت تصحیح مدار استفاده می‌شود. به طور خاص، داده‌های BPM را می‌توان برای آموزش مدل‌های یادگیری ماشین برای پیش‌بینی دامنه‌های بهینه ضربه‌زن‌های مرتبط با موقعیت‌های باریکه مورد استفاده قرار داد. الگوریتم‌های یادگیری تحت نظارت، از جمله شبکه‌های عصبی، ماشین‌های بردار پشتیبان^۲ و جنگل تصادفی^۳، گزینه‌های مناسبی برای این پیش‌بینی هستند. یادگیری ماشینی به دلیل توانایی در انطباق با روابط غیرخطی و پرداختن به وابستگی‌های پیچیده در داده‌ها، از مزیت‌های برجسته‌ای برخوردار است. این روش‌ها انعطاف‌پذیری بالایی دارند و به راحتی با وضعیت‌های پیچیده‌ای که ممکن است برای روش ISVD چالش‌برانگیز باشند، سازگار می‌شوند. در حالی که روش ISVD ممکن است در مواجهه با برخی شرایط پیچیده دچار مشکل شود، یادگیری ماشینی قادر است با بهره‌گیری از داده‌های موجود، این موقعیت‌ها را به درستی ترکیب و اصلاح کند. با این حال، اثربخشی مدل‌های یادگیری ماشینی به کیفیت و بازنمایی داده‌های آموزشی بستگی دارد. علاوه بر این، ماهیت «جعبه سیاه» برخی از مدل‌های یادگیری ماشینی ممکن است مانع از تفسیرپذیری نتایج شود و چالش‌هایی را در درک سازوکارهای فیزیکی زیربنایی که پیش‌بینی‌ها را هدایت می‌کنند، ایجاد کند.

در مقابل، روش ISVD شامل به‌کارگیری روش SVD به‌صورت تکراری روی داده‌های BPM برای تخمین دامنه ضربه‌زن است. در اینجا دامنه ضربه‌زن، میزان قدرت الکترومغناطیس در واحد رادبان برای اعمال انحراف در باریکه الکترونی است که می‌تواند مقداری مثبت یا منفی داشته باشد. روش ISVD تجزیه ماتریس داده BPM را به بردارها و مقادیر منفرد تسهیل می‌کند و امکان شناسایی حالت‌های غالب تغییرات را فراهم می‌کند. اصلاح مکرر این فرایند امکان استخراج دامنه‌های ضربه‌زن مربوط به موقعیت‌های باریکه خاص را فراهم می‌کند. مزیت اصلی روش ISVD در شفافیت و تفسیرپذیری آن نهفته است، زیرا بینش فیزیکی را می‌توان

1. Iterative Singular Value Decomposition (ISVD)

2. Support Vector Machine

3. Random Forest

4. Self Describing Data Sets (SDDS Files)



بین مقادیر پیش‌بینی شده و واقعی را اندازه‌گیری می‌کند، به حداقل می‌رسانیم. در این مدل، از تابع میانگین مربعات خطا^۷ به‌عنوان تابع زیان استفاده شده است. همچنین یک بهینه‌ساز آدام^۸ به‌عنوان الگوریتم یادگیری عمل می‌کند. ما از این مدل به‌عنوان یک کنترل‌کننده^۹ عصبی مصنوعی یاد می‌کنیم. با توجه به متعام بودن محورهای عرضی و تفکیک محاسبات برای آن‌ها، این رویکرد می‌تواند در پژوهش‌های آتی به طور مشابه برای داده‌های محور عمودی نیز اعمال شود.

۱.۳ سامانه‌های کنترلی

سامانه‌های کنترلی، حوزه‌ای از مطالعه است که بر روی سامانه‌های پویا و سازوکارهای بازخورد مرتبط با آن‌ها تمرکز دارد و از آن‌ها می‌توان برای تنظیم پدیده‌های مختلف مانند دما، سرعت، فشار و غیره استفاده کرد. این سامانه‌ها بسته به استفاده یا عدم استفاده از بازخورد می‌توانند حلقه‌باز یا حلقه‌بسته^۹ باشند. سامانه‌های حلقه‌بسته عملکرد بهتری دارند، اما پیچیده‌تر هستند. سامانه‌های کنترلی در حوزه‌های مختلف مانند هوافضا، رباتیک، سامانه‌های قدرت، مهندسی زیست‌پزشکی و غیره کاربردهای زیادی دارند. همچنین می‌توان آن‌ها را با فناوری‌های دیگر مانند سنجش، ارتباطات و تصمیم‌گیری برای ایجاد سامانه‌های هوشمند ادغام کرد. سامانه‌های کنترلی یک حوزه تحقیقاتی فعال و بین‌رشته‌ای است که دارای موضوعات و چالش‌های فراوانی است، مانند کنترل غیرخطی و تطبیقی، کنترل بهینه و تصادفی، کنترل توزیع‌شده و شبکه‌ای، کنترل یادگیری و داده‌محور، کنترل تحمل‌پذیر و ایمن. هدف تحقیق سامانه‌های کنترلی توسعه نظریه‌ها، روش‌ها و ابزارهای جدید برای آینده مدرن است [۱۸، ۱۹].

در یک شتابگر سنکروترون چشمه نور، کنترل دقیق بر عامل‌های شتاب ذرات و باریکه برای عملکرد آن ضروری است. با تنظیم میدان‌های مغناطیسی، کاواک‌های بسامد رادیویی و سایر اجزا، می‌توان مسیر و انرژی ذرات را تعیین کرد. این سطح کنترل تضمین می‌کند که ذرات مسیر موردنظر را دنبال می‌کنند و در نتیجه تابش سنکروترون با کیفیت مطلوب به‌دست می‌آید؛ بنابراین می‌توان عملکرد ضربه‌زن را در کنترل باریکه به‌عنوان یک سامانه کنترلی در نظر گرفت، زیرا هر دو شامل مدیریت و تنظیم فرایندهای پویا برای دستیابی به نتایج خاص هستند. باید تأکید کرد که ضربه‌زن نقش بسزایی در کنترل باریکه و همچنین حفظ پایداری آن دارد.

رویکرد یادگیری ماشینی که استفاده شده مبتنی بر یک مدل شبکه عصبی پیچشی (CNN)^۱ است. در این معماری شبکه داده‌ها در گروه‌های هم‌جوار از طریق یک هسته پردازش می‌شوند. مانند تأثیری که یک فیلتر تصویر روی پیکسل‌های آن انجام می‌دهد. شبکه CNN نوعی شبکه عصبی مصنوعی است که می‌تواند ویژگی‌ها را با استفاده از چندین لایه فیلتر و فعال‌سازی‌های غیرخطی استخراج کند. این شبکه می‌تواند داده‌های با ابعاد زیاد و همبستگی فضایی مانند تصاویر یا سیگنال‌های صوتی را مدیریت کند و به‌دقت و تعمیم زیادی دست یابد. معماری این شبکه از ترکیبی از لایه‌های پیچشی^۲، جمع‌حداکثری^۳ و کاملاً متصل^۴ برای یادگیری خودکار و تطبیقی سلسله‌مراتب فضایی ویژگی‌ها از داده‌های ورودی استفاده می‌کند. این امر به آن اجازه می‌دهد تا الگوهای پیچیده را در داده‌ها شناسایی کند و آن‌ها را در مدیریت داده‌های با ابعاد زیاد و مجموعه داده‌های بزرگ مؤثرتر می‌کند. شبکه‌های عصبی پیچشی می‌توانند ویژگی‌هایی را بیاموزند که نسبت به تبدیل‌ها ثابت هستند، از ساختار محلی و همبستگی داده‌ها بهره‌برداری کنند و عامل‌های کمتر و تعمیم بهتری نسبت به «پرسپترون چندلایه»^۵ (MLP) دارند. شبکه MLP هر ورودی را مستقل تلقی می‌کند و روابط فضایی یا زمانی بین آن‌ها را در نظر نمی‌گیرد؛ بنابراین می‌توان دنباله از BPMها را به‌عنوان یک ورودی یک‌بعدی برای CNN در نظر گرفت. پردازش داده‌های BPMهای هم‌جوار می‌تواند مقادیر بهینه دامنه ضربه‌زن‌ها را پیش‌بینی کند.

۳. روش پیشنهادی

در این مطالعه، برای اولین بار یک معماری CNN برای کنترل باریکه ELETTRA ۲.۰ به کار گرفته شده است. مدل CNN با استفاده از داده‌های جمع‌آوری شده از حلقه انبارش ELETTRA ۲.۰ در طول عملکرد عادی آن در شبیه‌سازی با نرم‌افزار ELEGANT آموزش داده شده است. در اینجا از یک روش یادگیری نظارت شده مبتنی بر CNN استفاده شده که در آن جفت‌های ورودی خروجی BPM و دامنه ضربه‌زن در محور افقی را به مدل CNN ارائه داده و یک تابع زیان^۶ را که تفاوت

1. Convolutional Neural Network (CNN)
2. Convolutional Layers
3. Pooling
4. Fully Connected
5. Multilayer Perceptron (MLP)

پرسپترون چندلایه، یک مدل از شبکه عصبی مصنوعی است که متشکل از چندین لایه نورون‌های کاملاً متصل برای پردازش داده‌ها است.

6. Loss Function

7. Mean Squared Error (MSE)

8. ADAM

9. Closed-Loop Control Systems (CLCS)



۲.۳ کنترل کننده عصبی هوشمند

ReLU غیرخطی و پراکندگی را به نقشه ویزگی معرفی می‌کند. لایه تجمع حداکثری با انتخاب حداکثر مقدار در هر منطقه، ابعاد و نوفه نقشه ویزگی را کاهش می‌دهد. لایه خروجی از یک لایه کاملاً متصل تشکیل شده است که نقشه ویزگی نهایی را به یک بردار یک‌بعدی به طول M ترسیم می‌کند. شکل ۳ جزئیات مدل CNN را نشان می‌دهد [۲۴، ۲۵]. این معماری برای تحلیل و پردازش داده‌های متوالی با رابطه مکانی مناسب است. در مدل کنترل کننده از چندین لایه پیچشی با فیلترهای مختلف استفاده شده تا بتوان ویزگی‌های سلسله مراتبی را از داده‌های ورودی استخراج کرد. استفاده از ترکیب لایه‌های پیچشی، تجمع حداکثری و حذف، پیچیدگی و عملکرد مدل را متعادل می‌کند تا دقت بالای مدل بدون برازش بیش از حد آن به دست آید. همچنین استفاده از لایه نرمال‌سازی دسته‌ای و حذف به‌عنوان تکنیک‌های منظم‌سازی، توانایی مدل برای تعمیم به داده‌های جدید را افزایش می‌دهد.

این مطالعه عملکرد مدل‌های آموزش‌دیده^۴ را با استفاده از دو معیار ارزیابی می‌کند: میانگین مربعات خطا و میانگین خطای مطلق نرمال شده^۵. سنجه MSE میانگین مجذور انحراف بین مقادیر پیش‌بینی شده و واقعی ضربه‌زن‌ها را اندازه‌گیری می‌کند، درحالی‌که NMAE با تقسیم میانگین خطای مطلق (MAE) بر دامنه مقادیر مشاهده شده محاسبه می‌شود، که خطا را به مقادیری بین صفر و یک نرمال‌سازی می‌کند. در این سنجه، مقادیر NMAE بیشتر نشان‌دهنده درجه کمتری از مطابقت است و برعکس. علاوه‌براین، برای درک بهتر می‌توان آن را به صورت درصد نیز بیان کرد.

۴.۳ رگرسیون بردار پشتیبان (SVR)^۶

به طور خلاصه، روش رگرسیون بردار پشتیبان یک الگوریتم یادگیری ماشینی است که برای تحلیل رگرسیون استفاده می‌شود. هدف اصلی SVR در یادگیری ماشینی، یافتن تابعی است که رابطه بین متغیرهای ورودی و یک متغیر پیوسته خروجی را تقریب زده و درعین حال خطای پیش‌بینی را به حداقل رساند. این روش معمولاً با استفاده از توابع هسته^۷، می‌تواند به‌صورت خطی یا غیرخطی عمل کند. در مواردی که رابطه‌ها پیچیده‌تر یا الگوهای غیرخطی در داده‌ها وجود دارد، SVR به‌عنوان یک روش قدرتمند برای حل مسائل رگرسیون مورد استفاده قرار می‌گیرد [۲۶].

کنترل کننده‌های عصبی هوشمند نوعی از روش‌های کنترل هوشمند هستند که از شبکه‌های عصبی مصنوعی^۱ برای مدل‌سازی، طراحی، بهینه‌سازی و تنظیم سامانه‌های کنترل حلقه‌بسته استفاده می‌کنند. سامانه‌های کنترلی حلقه‌بسته سامانه‌هایی هستند که از بازخورد حسگرها برای تنظیم متغیرهای کنترلی یک فرایند یا یک سامانه به‌صورت زمان واقعی استفاده می‌کنند. سیستم‌های کنترل حلقه‌بسته، برتری‌های زیادی نسبت به سیستم‌های کنترل حلقه‌باز دارند. یکی از این موارد برتری، حساسیت کم‌تر پاسخ سیستم نسبت به اغتشاش‌های خارجی و تغییر پارامترهای سیستم است. البته باید توجه کرد که در صورت طراحی اشتباه سیستم کنترل حلقه‌بسته، امکان ناپایداری سیستم وجود دارد. شبکه‌های عصبی مصنوعی مدل‌های محاسباتی هستند که می‌توانند از داده‌ها یاد بگیرند و توابع غیرخطی پیچیده را تقریب بزنند. کنترل کننده‌های عصبی هوشمند می‌توانند عملکرد و مقاومت سامانه‌های کنترلی حلقه‌بسته را بهبود بخشند، به‌ویژه برای فرایندهای چندمتغیره و غیرخطی که کنترل آن‌ها با روش‌های مرسوم دشوار است. کنترل کننده‌های عصبی هوشمند همچنین می‌توانند با محیط‌ها و اختلالات در حال تغییر سازگار شوند و با استفاده از روش‌های یادگیری ماشین، وضعیت آینده سامانه را پیش‌بینی کنند [۲۰-۲۲].

در این بررسی چشمه نور به‌عنوان یک سامانه کنترلی و ضربه‌زن به‌عنوان کنترل کننده در نظر گرفته شده است، بنابراین می‌توان اثر کنترل کننده را با BPMها اندازه‌گیری کرد. همان‌طور که در مقدمه نیز اشاره شد، تنها چند مطالعه در این زمینه خاص انجام شده است [۴، ۶].

۳.۳ شبکه عصبی پیچشی

مدل CNN دارای سه لایه اصلی است: لایه ورودی، لایه پنهان و لایه خروجی [۲۳]. لایه ورودی از یک بردار تک‌بعدی به طول N تشکیل شده است. لایه پنهان شامل چند بلوک پیچشی است که هر کدام دارای یک لایه پیچشی، یک لایه نرمال‌سازی دسته‌ای، یک تابع فعال‌سازی واحد خطی اصلاح شده^۲ و یک لایه تجمع حداکثری^۳ است. لایه پیچشی مجموعه‌ای از فیلترها را به بردار ورودی اعمال می‌کند و یک نقشه ویزگی تولید می‌کند. لایه نرمال‌سازی دسته‌ای، نقشه ویزگی را نرمال می‌کند و ثبات و سرعت تمرین را بهبود می‌بخشد. تابع فعال‌سازی

4. Trained

5. Normal Mean Absolute Error (NMAE)

6. Support Vector Regression (SVR)

7. Kernel Functions

Journal of Nuclear Science, Engineering and Technology


Vol. 46 (2), Serial Number 112, 2025, P 135-147

1. Artificial Neural Controller (ANN)

2. Rectified Linear Unit (ReLU)

3. Max Pooling





شکل ۳. نمایش یک شبکه عصبی پیچشی.

براساس فرایند کنترل طراحی شده در ELETTRA ۲.۰.

دامنه ضربزن در ۱۱ دور متوالی اعمال می‌شود (شکل ۴)؛ بنابراین، مقادیر BPMها در باریکه اصلاح نشده به‌عنوان BPM0 استفاده می‌شود و عمل اصلاح تا به‌دست آمدن BPM۱۱ ادامه پیدا می‌کند.

میانگین خطای مطلق نرمال شده برای مدل CNN ۲٫۴۹ درصد و برای مدل SVR ۱٫۴۹ درصد است. در ادامه می‌توان از هریک از آنها برای تخمین نتایج کنترل‌کننده عصبی مصنوعی استفاده کرد. برای نمونه، پاسخ مدل SVR سامانه به داده‌های آزمون براساس فرایند کنترلی شتابگر در برخی از BPMها در شکل ۵ بررسی شده است. نزدیکی نقاط به خط صفر در تمام نمودارها نشان‌دهنده بهبود موقعیت باریکه و پایداری آن در مرکز محفظه خلأ پس از اصلاح است. در این شکل داده $\text{trun}=\infty$ موقعیت باریکه در وضعیت تصحیح نشده و نقاط بعدی موقعیت باریکه در دوره‌های متوالی بعدی را نشان می‌دهد؛ بنابراین، مدل عصبی سامانه می‌تواند رفتار سامانه را نشان داده و تخمین قابل‌اعتمادی از آن به دست دهد.

۲.۴ طراحی کنترل‌کننده عصبی مصنوعی

در ادامه، مدل CNN کنترل‌کننده عصبی مصنوعی با محاسبه‌ای که از روش ISVD برای به‌دست آوردن مقدار دامنه ضربزن‌ها به‌ازای مقدار BPMها استفاده می‌کند را مقایسه می‌کنیم. عملکرد مدل کنترل‌کننده آموزش‌دیده به‌تفصیل در جدول ۴ نشان داده شده است. لایه ورودی مقادیر BPMها برای باریکه اصلاح نشده را به‌عنوان یک بردار تک‌بعدی به طول ۱۶۸ دریافت می‌کند. لایه خروجی از یک بردار تک‌بعدی به طول ۲۴ تشکیل شده است که مقادیر پیش‌بینی شده برای دامنه ضربزن را نشان می‌دهد. بنابراین، برای اندازه N مقدار ۱۶۸ و برای اندازه M مقدار ۲۴ را در شکل ۳ داریم. همچنین جزئیات نقشه ویژگی‌های شبکه فوق در شکل ۶ نشان داده شده است.

۴. نتایج و بررسی

در این بخش، نتایج مطالعه ارائه می‌گردد. ابتدا در مورد شناسایی سامانه بحث شده و نتایج آن تشریح می‌شود. سپس نتایج به‌دست‌آمده از کنترل‌کننده عصبی مصنوعی طراحی شده ارائه خواهد شد. در اینجا منظور از سامانه، شتابگر چشمه نور سنکروترونی است.

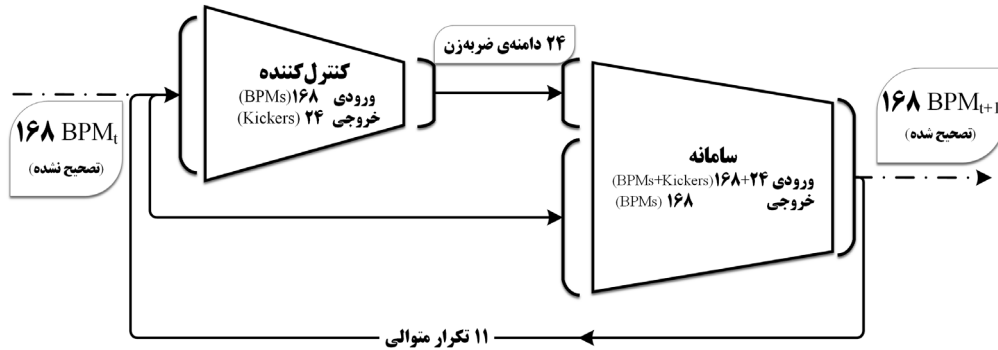


۱.۴ شناسایی رفتار سامانه

این مطالعه از تحلیل رگرسیون استفاده می‌کند که ذاتاً منجر به اختلاف بین نتایج کنترل‌کننده و داده‌های آموزشی می‌شود. در درجه اول، ارزیابی کارایی مدل کنترل‌کننده مصنوعی نیاز به مدلی دارد که دقیقاً رفتار باریکه را در شتابگر مشخص کند. این مستلزم کمی‌سازی خروجی‌های کنترل‌کننده برای تعیین میزان افزایش مداری و هم‌گرایی آن به سمت حالت ایده‌آل انحراف صفر و رسیدن به مدار بسته است. برای این ارزیابی باید مدلی آموزش داده شود که رفتار باریکه پس از اعمال دامنه ضربزن‌ها را مشخص کند. به این منظور مدل رگرسیون چند خروجی [۲۷] با استفاده از روش‌های مختلف آموزش داده شده است: (۱) روش رگرسیون بردار پشتیبان (SVR) و (۲) یک مدل پیچشی. مدل پیچشی شبیه مدل شکل ۳ است که در آن اندازه لایه ورودی N برابر ۱۹۲ است (البته با در نظر گرفتن جداسازی ورودی ۱۶۸ BPM از ۲۴ ضربزن در لایه پیچشی) و اندازه لایه خروجی M برابر ۱۶۸ است. لایه ورودی مقادیر اندازه‌گیری شده توسط BPM برای باریکه تصحیح نشده و دامنه ضربزن‌ها به‌عنوان بردار تک‌بعدی طول $(168+24)$ را دریافت می‌کند. لایه خروجی از یک بردار تک‌بعدی به طول ۱۶۸ تشکیل شده است که مقادیر پیش‌بینی شده BPMها را پس از اصلاح با ضربزن‌ها نشان می‌دهد. جدول ۳ جزئیاتی از عملکرد مدل‌های سامانه سنکروترون آموزش‌دیده را نشان می‌دهد.



جدول ۳. ویژگی‌های مربوط به مدل‌های سامانه

پارامتر	کمینه مقدار BPM در داده‌های آزمون	بیشینه مقدار BPM در داده‌های آزمون	مقدار MAE در مدل CNN سامانه	مقدار MAE در مدل SVR سامانه	مقدار NMAE در مدل CNN سامانه	مقدار NMAE در مدل SVR سامانه
واحد	μm	μm	μm	μm	%	%
مقدار	-۴۱۲۶	۴۰۳۴	۲۰۳/۴۱	۲۰۳/۴۱	۲/۴۹۲۷	۱/۴۹۴۸

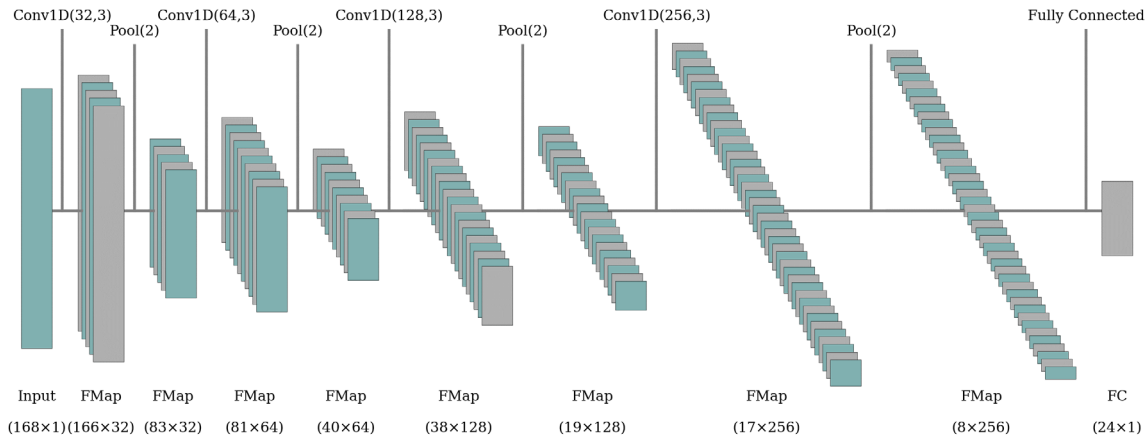
شکل ۴. خروجی سامانه کنترلی در دور $t+1$ دوباره به سامانه و کنترل کننده وارد می‌شود تا خروجی آن را برای دور بعدی تولید کند.

شکل ۵. تطبیق پاسخ مدل سامانه برای برخی از داده‌های آزمون (BPM ۱۶۸ + 24 ضربه‌زن) در هر دور.



جدول ۴. ویژگی‌های مربوط به مدل کنترل‌کننده عصبی مصنوعی

پارامتر	کمینه دامنه ضربه‌زن در داده‌های آزمون	بیشینه دامنه ضربه‌زن در داده‌های آزمون	خطای MAE مدل کنترل‌کننده مصنوعی	خطای NMAE مدل کنترل‌کننده مصنوعی
واحد	μrad	μrad	μrad	%
مقدار	-۲۴۳٫۸۷	۱۹۳٫۰۶	۱۸٫۷۴۲	۴٫۲۸۹۳



شکل ۶. جزئیات مدل کنترل‌کننده عصبی مصنوعی.

در بسیاری از موارد مدل‌های آموزش داده شده بر روی داده‌های آموزش و یا داده‌های آزمون که توزیع احتمالاتی مشابهی با داده‌های آموزش دارند عملکرد قابل‌قبولی ارائه می‌دهند؛ اما در بسیاری از موارد کاربردی و صنعتی این چالش وجود دارد که ممکن است داده‌های ورودی به مدل، الگویی مشابه با داده‌های آموزش نداشته باشند؛ از این رو مقاومت مدل در مواجهه با تغییرات الگوی داده‌های ورودی، همواره از مهم‌ترین شاخص‌های شبکه‌های عصبی مصنوعی بوده است. به طور خاص مقاومت در شبکه‌های عصبی مصنوعی، توانایی شبکه برای حفظ عملکرد در هنگام مواجهه با تغییر الگوی داده‌های ورودی مانند اختلالات ورودی و یا نوفه تعریف می‌شود. مقاومت ANNs شاخصی حائز اهمیت در مسائل کاربردی دنیای واقعی است، به‌ویژه آن‌هایی که از نظر ایمنی حیاتی هستند، مانند رانندگی خودران یا تشخیص پزشکی، بسیار مهم است.

در این مطالعه، برای تولید داده‌های شبیه‌سازی شده مقدار خطایی جزئی در هم‌راستایی و شیب تجهیزات اعمال شد که کنترل‌کننده عصبی مصنوعی قادر به شناسایی و تصحیح مدار آن نیز گردید. همچنین به‌عنوان پیشنهاد برای مطالعات بعدی می‌توان برای «اعتبارسنجی مقاومت»^۲، رفتار همین کنترل‌کننده عصبی مصنوعی در مواجهه با داده‌هایی که شامل سایر منابع خطا هستند را نیز بررسی کرد.

نمودار تغییرات مقدار تابع زیان برای مدل کنترل‌کننده عصبی مصنوعی در شکل ۷ نشان داده شده است. علاوه بر این، نمونه‌ای از تطبیق پاسخ مدل کنترل‌کننده با داده‌های ورودی در شکل ۸ نشان داده شده است. نتایج نشان می‌دهد که مدل ارائه شده، یک مدل مناسب برای پیش‌بینی مقادیر دامنه ضربه‌زن براساس ورودی است.

شکل ۹ پاسخ مدل سامانه به دامنه ضربات پیش‌بینی شده توسط کنترل‌کننده عصبی مصنوعی را در مقایسه با روش ISVD نشان می‌دهد. همان‌طور که نشان داده شده، کنترل‌کننده طراحی شده عملکردی قابل مقایسه با روش ISVD به دست می‌دهد. برای بررسی دقیق‌تر، نتایج ارزیابی عملکرد مدل روی داده‌های آزمون، مقدار MAE خروجی سامانه از مقدار مرجع یعنی صفر (که خروجی مطلوب سامانه یا مرجع سامانه کنترل است) در تمام نقاط تصحیح شده برای هر یازده دور و به ازای همه BPMها در جدول ۵ نشان داده شده است. به عبارت دیگر، به دلیل مقاومت^۱ بهتر شبکه عصبی، در مجموع پاسخ کنترل‌کننده طراحی شده نزدیک‌تر از پاسخ‌های تولید شده توسط روش ISVD به نقطه مرجع (صفر) است.

2. Robustness Verification

Journal of Nuclear Science, Engineering and Technology


Vol. 46 (2), Serial Number 112, 2025, P 135-147

1. Robustness

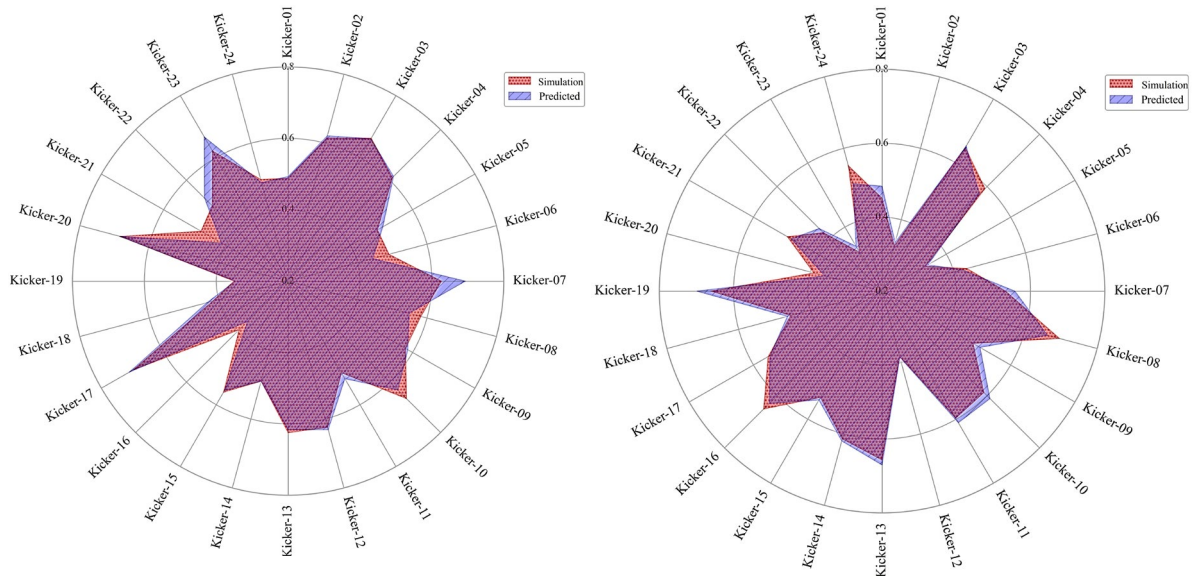
مجله علوم، مهندسی و فناوری هسته‌ای

دوره ۴۶، شماره ۲، جلد ۱۱۲، تابستان ۱۴۰۴، ص ۱۳۵-۱۴۷






شکل ۷. پاسخ تابع زیان برای داده‌های آموزشی و آزمون در مدل کنترل‌کننده.



شکل ۸. تطبیق پاسخ مدل کنترل‌کننده با داده‌های آزمون. خروجی‌ها در محدوده صفر تا یک با استفاده از روش «مقیاس‌کننده حداقل‌حداکثر» نرمال‌سازی شده‌اند.

جدول ۵. مقدار MAE پاسخ سامانه نسبت به مرجع کنترلی برای روش ISVD و مدل کنترل‌کننده عصبی مصنوعی

مقدار	واحد مقدار
۱۵۶٫۰۴۷	روش ISVD
۱۴۶٫۰۹۳	کنترل‌کننده عصبی مصنوعی



شکل ۹. مقایسه پاسخ سیستم به کنترل‌کننده عصبی مصنوعی و روش ISVD در هر دور تصحیح متوالی.

۵. نتیجه‌گیری

اگرچه تصحیح مدار مبتنی بر یادگیری ماشینی هنوز در مرحله اولیه توسعه خود است، نتیجه این مطالعه نشان می‌دهد که فنون یادگیری ماشین می‌تواند به‌عنوان یک رویکرد جایگزین برای تصحیح خودکار مدار چشمه‌های نور سنکروترون مانند حلقه انبارش شتابگر ۲.۰ ELETTRA استفاده شود. با ترکیب حلقه انبارش واقعی براساس جمع‌آوری داده‌های آموزشی، فن یادگیری ماشینی کاربردی می‌تواند ذاتاً حتی در مواجهه با عیوب ماشین مانند عیوب غیرخطی (مانند خطاهای هم‌راستایی شش‌قطبی) یا سایر چندقطبی‌های مرتبه بالاتر به دلیل اثرات میدان مغناطیسی آموزش داده شود. علاوه بر این، اگرچه پتانسیل فنون یادگیری ماشینی هنوز به طور کامل مورد بهره‌برداری قرار نگرفته است، اما مطابق نتایج به‌دست آمده، خطای مدار باقی‌مانده در آن حدود ۶ درصد کمتر از روش‌های مبتنی بر SVD است. شایان‌ذکر است که این فنون نسبت به سایر روش‌ها در شرایطی که روابط حاکم بین متغیرهای سیستم (داده‌ها)، پیچیده و غیرخطی هستند، پتانسیل عملکرد بهتری دارند.

در این مطالعه، از داده‌های خروجی یک کنترل‌کننده مبتنی بر ISVD برای آموزش یک کنترل‌کننده CNN استفاده شده است. سپس مدل CNN آموزش داده شده برای تولید مقادیر بهینه دامنه ضربه‌زن‌ها برای تصحیح مدار باریکه الکترونی به کار گرفته شد. دستاورد مهم به‌دست آمده در این مطالعه این است که با وجود اینکه کنترل‌کننده CNN با استفاده از داده‌های روش ISVD آموزش داده شده است، عملکرد بهتری در مقایسه با کنترل‌کننده مبتنی بر ISVD دارد. علت این پدیده، توانایی بیشتر CNN برای ایجاد روابط غیرخطی بین بازخورد کنترلی از BPMها و سیگنال کنترلی متناسب با آن در ضربه‌زن‌ها است. روش ISVD به دلیل ساختار خطی و بسیار ساده، محدودیت بیشتری برای تولید سیگنال کنترلی دقیق‌تر بر روی سامانه شتابگر در تمام وضعیت‌های کنترلی دارد (در اینجا منظور از وضعیت‌های کنترلی، دوره‌های مختلف حرکت الکترون در حلقه انبارش شتابگر هستند). CNN علاوه بر یادگیری مفهوم کلی کنترل سامانه از داده‌های روش ISVD، به دلیل ظرفیت ساختاری پیچیده خود، انعطاف‌پذیری بیشتری در مواجهه با وضعیت‌های کنترلی متنوع دارد.



مراجع


1. Leemann S.C, Liu S, Hexemer A, Marcus M.A, Melton C.N, Nishimura H, Sun C. Demonstration of Machine Learning-Based Model-Independent Stabilization of Source Properties in Synchrotron Light Sources. *Phys Rev Lett.* 2019 Nov 6;123(19):194801.
2. Bartolini R. Storage Ring Design for Synchrotron Radiation Sources. In: Jaeschke EJ, Khan S, Schneider JR, Hastings JB, editors. *Synchrotron Light Sources and Free-Electron Lasers [Internet]. Cham: Springer International Publishing; 2016 [cited 2024 Jan 16]. 253–302. Available from: https://link.springer.com/10.1007/978-3-319-14394-1_7.*
3. Shin S. New era of synchrotron radiation: fourth-generation storage ring. *AAPPS Bull.* 2021 Dec;31(1):21.
4. Schirmer D. Intelligent Controls for the Electron Storage Ring DELTA. *Proceedings of the 9th Int Particle Accelerator Conf.* 2018;IPAC2018:4 pages, 1.097 MB.
5. Koetter S, Riemann B, Isbarn B.D, Sommer M, Weis T. Evaluation of a Cone-Program Based Approach to Orbit Correction at the Electron Storage Ring Delta. *Verhandlungen der Deutschen Physikalischen Gesellschaft.* 2018;(Wuerzburg2018issue):1.
6. Schirmer D. A machine learning approach to electron orbit control at the 1.5 GeV synchrotron light source DELTA. *J Phys: Conf Ser.* 2023 Jan 1;2420(1):012069.
7. Brown K, Binello S, D'Ottavio T, Dyer P, Nemesure S, Thomas D. Experience with Machine Learning in Accelerator Controls. *Proceedings of the 16th Int Conf on Accelerator and Large Experimental Control Systems.* 2018;ICALEPCS2017:7 pages, 0.935 MB.
8. Edelen A.L, Biedron S.G, Chase B.E, Edstrom D, Milton S.V, Stabile P. Neural Networks for Modeling and Control of Particle Accelerators. *IEEE Trans Nucl Sci.* 2016 Apr;63(2):878–97.
9. Vera Ramirez L, Hartmann G, Mertens T, Müller R, Viefhaus J. Adding Machine Learning to the Analysis and Optimization Toolsets at the Light Source BESSY II. *Proceedings of the 17th International Conference on Accelerator and Large Experimental Physics Control Systems.* 2020;ICALEPCS2019:7 pages, 2.836 MB.
10. Hanuka A, Huang X, Shtalenkova J, Kennedy D, Edelen A, Zhang Z, Lalchand V.R, Ratner D, Duris J. Physics model-informed Gaussian process for online optimization of particle accelerators. *Phys Rev Accel Beams.* 2021 Jul 8;24(7):072802.
11. Karantzoulis E, Carniel A, Castronovo D, Di Mitri S, Diviacco B, Krecic S. Elettra and Elettra 2.0. *Proceedings of the 12th International Particle Accelerator Conference.* 2021;IPAC2021:3 pages, 0.511 MB.
12. Karantzoulis E, Barletta W. Aspects of the Elettra 2.0 design. *Nucl. Instrum. Methods Phys. Res. A,* 2019 May;927:70–80.
13. Karantzoulis E, Di Mitri S, Barbo F, Barletta W, Bassanese S, Bracco R, Design strategies and technology of Elettra 2.0 for a versatile offer to the user community. *Nucl. Instrum. Methods Phys. Res. A,* 2024 Mar;1060:169007.
14. Baird S. Accelerators for pedestrians [Internet]. CERN. Geneva. AB Department; 2007 Feb p. 155. (Accelerators and Storage Rings). Report No.: AB-Note-2007-014; CERN-AB-Note-2007-014; PS-OP-Note-95-17-Rev-2; CERN-PS-OP-Note-95-17-Rev-2. Available from: <https://cds.cern.ch/record/1017689/files/ab-note-2007-014.pdf>.
15. Chung Y, Decker G, Evans K. Closed orbit correction using singular value decomposition of the response matrix. In: *Proceedings of International Conference on Particle Accelerators.* 1993;3:2263–5.
16. Borland M. ELEGANT: A flexible SDDS-compliant code for accelerator simulation [Internet]. 2000 Aug [cited 2024 Feb 3] LS-287, 761286. Report No.: LS-287, 761286. Available from: <http://www.osti.gov/servlets/purl/761286/>.
17. PART THREE: Machine and Infrastructure [Internet]. *Elettra-Sincrotrone Trieste;* p. 469. Available from: <https://www.elettra.eu/images/Documents/ELETTRA%20Machine/Elettra2/TDR-Machine-Infrastructures-Final-compresso.pdf>.
18. Benjamin C, Golnaraghi F. Automatic control systems. *John Wiley and Sons.* 2010.
19. Ogata K. Modern control engineering. *Pearson, 5th edition.* 2010.
20. Limon D, Calliess J, Maciejowski J.M. Learning-based Nonlinear Model Predictive Control. *IFAC-PapersOnLine.* 2017;50(1):7769–76.
21. Abiodun O.I, Jantan A, Omolara A.E, Dada K.V, Mohamed N.A, Arshad H. State-of-the-art in artificial neural network applications: A survey. *Heliyon.* 2018 Nov;4(11):e00938.
22. Emami S.A, Castaldi P, Banazadeh A. Neural network-based flight control systems: Present and future. *Annual Reviews in Control.* 2022;53:97–137.
23. Li Z, Yang W, Peng S, Liu F. A Survey of Convolutional Neural Networks: Analysis, Applications, and Prospects. *CoRR [Internet].* 2020;abs/2004.02806. Available from: <https://arxiv.org/abs/2004.02806>.
24. LeCun Y, Bengio Y, Hinton G. Deep learning. *Nature.* 2015 May 28;521(7553):436–44.
25. Kiranyaz S, Avci O, Abdeljaber O, Ince T, Gabbouj M, Inman D.J. 1D convolutional neural networks and applications: A survey. *Mechanical Systems and Signal Processing.* 2021 Apr;151:107398.

26. Smola A.J, Schölkopf B. A tutorial on support vector regression. *Statistics and computing*. 2004;14:199–222.

27. Borchani H, Varando G, Bielza C, Larranaga P. A survey on multi-output regression. *Wiley Interdisciplinary Reviews: Data Mining and Knowledge Discovery*. 2015;5(5):216–33.

COPYRIGHTS

©2021 The author(s). This is an open access article distributed under the terms of the Creative Commons Attribution (CC BY 4.0), which permits unrestricted use, distribution, and reproduction in any medium, as long as the original authors and source are cited. No permission is required from the authors or the publishers.



استناد به این مقاله

یزدانی، محمدصادق، مسعودی، سیدفرهاد، رحیقی، جواد، داستان، سارا. (۱۴۰۴). کنترل باریکه الکترون حلقه انبارش شتابگر ۲.۰ ELETTRA با استفاده از یادگیری ماشین. *مجله علوم، مهندسی و فناوری هسته‌ای*، ۱۱۲(۲)، ۱۳۵–۱۴۷. DOI: <https://doi.org/10.24200/nst.2024.1598.2034>. Url: https://jonsat.nstri.ir/article_1688.html.

