

بسم الله الرحمن الرحيم



نشریه سامانه‌های غیرخطی در مهندسی برق

دوره ۱۲، شماره ۲، پاییز و زمستان ۱۴۰۴



ISSN: 2322-3146

صاحب امتیاز: دانشگاه صنعتی سهند - معاونت پژوهش و فناوری

مدیر مسئول: دکتر رضا فلاح

سرمدیر: دکتر علی بهرامی

مدیر اجرایی: خانم دکتر آرزو جهانی

ناشر: دانشگاه صنعتی سهند با همکاری مرکز منطقه‌ای اطلاع‌رسانی علوم و فناوری و پایگاه استنادی علوم جهان اسلام (ISC)

حروفچینی و صفحه‌آرایی: دکتر آرزو جهانی

هیأت تحریریه:

دکتر بهنام محمدی ایواتلو - استاد گروه قدرت دانشگاه LUT فنلاند

دکتر فرزاد هاشم زاده - استاد گروه کنترل دانشگاه ITU ترکیه

دکتر علی رستمی - استاد گروه الکترونیک دانشگاه تبریز

دکتر فرخ مروستی - استاد گروه مخابرات دانشگاه صنعتی شریف

دکتر آرش امینی - استاد گروه مخابرات دانشگاه صنعتی شریف

دکتر محمداقبر شمس‌اللهی - استاد گروه مهندسی پزشکی دانشگاه صنعتی شریف

دکتر افشین ابراهیمی - استاد گروه مخابرات دانشگاه صنعتی سهند تبریز

دکتر اسماعیل نجفی اقدم، استاد گروه الکترونیک دانشگاه صنعتی سهند تبریز

دکتر اکبر غفارپور رهبر - استاد گروه مهندسی کامپیوتر دانشگاه صنعتی سهند تبریز

دکتر علی بهرامی - استاد گروه الکترونیک دانشگاه صنعتی سهند تبریز

گروه ویراستاری: دکتر رسول کاظم زاده، دکتر رضا محبوبی و دکتر معصومه آذغانی

نشریه سامانه‌های غیرخطی در مهندسی برق با مجوز شماره ۱۵۹۸۱۱/۳/۱۸ مورخ ۱۳۹۱/۰۸/۰۲ و کسب اعتبار علمی-پژوهشی با مجوز شماره ۱۰۲۶۱/۱۸/۳ مورخ ۱۳۹۶/۰۵/۱۵ از کمیسیون نشریات علمی-پژوهشی وزارت علوم، تحقیقات و فناوری به زبان فارسی منتشر شده و در پایگاه استنادی جهان اسلام (ISC) نمایه می‌شود. این نشریه تخصصی در راستای تحقق اهداف و توسعه مرزهای دانش و به منظور گسترش و نشر پژوهش‌های بنیادی، کاربردی و توسعه‌ای، مقالات اصیل علمی در گرایش‌های مختلف مهندسی برق و کامپیوتر که قبلاً در هیچ نشریه دیگری انتشار نیافته باشند را با تأکید بر تحلیل و طراحی سامانه‌های غیرخطی به چاپ می‌رساند. مطالب مندرج در مقالات صرفاً بیانگر نقطه نظرات نویسندگان بوده و این آراء لزوماً نظر مسئولین نشریه نیستند.

نشانی پستی نشریه: تبریز، شهر جدید سهند، پردیس دانشگاه صنعتی سهند، معاونت پژوهش و فناوری، دبیرخانه نشریات تخصصی دانشگاه،

کد پستی: ۵۳۳۱۸/۱۷۶۳۴

تلفن: ۰۴۱-۳۳۴۵۹۳۴۰ و ۰۴۱-۳۳۴۵۹۳۲۱ دورنگار: ۰۴۱-۳۳۴۴۳۸۷۷

پست الکترونیک: jnsee@sut.ac.ir سایت اینترنتی: <http://jnsee.sut.ac.ir>

نشریه سامانه‌های غیرخطی در مهندسی برق

دوره ۱۲، شماره ۲، پاییز و زمستان ۱۴۰۴

فهرست مقالات

عنوان	شماره صفحه
کنترل غیرمستقیم ولتاژ خروجی مبدل DC-DC افزایشده در حالت هدایت پیوسته با استفاده از کنترل‌کننده مقاوم مبتنی بر غیرفعال بودن و کنترل‌کننده PI حلقه بسته آبشاری نویسندگان: محمد هادی مولایی اردکانی، امیر حسین رجایی	۵
تحلیل خودکار چند پارامتری ضایعات مغزی در گذر زمان: یک چارچوب کامل یادگیری عمیق برای مشخصه‌سازی کمی نویسندگان: مهدی بشیری باویل، موسی شمسی، ابوالحسن شاکری باویل	۲۹
تشخیص و جبران رانش در سنسورهای گازی نیم‌رسانا با استفاده از مدل‌های یادگیری عمیق سبک و قابل استقرار روی سامانه‌های لبه نویسندگان: امیره سیدفرجی	۴۷
بهینه‌سازی مدولاتور سیگما-دلتا برای کاربردهای مهندسی پزشکی نویسندگان: یوسف بلقیس آذر، خلیل منفردی، موسی یوسفی	۷۳
سنکرون‌سازی سیستم‌های آشوبناک غیرکانونیکال نامعلوم با استفاده از کنترل مود لغزشی تطبیقی-فازی مقاوم نویسندگان: محمد صفری سوری، سید کمال الدین موسوی مشهدی، محمد فیوضی	۸۷
کنترل تشخیص ملانوما در تصاویر درموسکوپ با استفاده از هم‌جوشی ویژگی‌های عمیق DenseNet121 و ویژگی‌های بافتی LNDP نویسندگان: نفیسه غلامی، منصور زینلی	۱۰۹

Journal of Nonlinear Systems in Electrical Engineering

Vol. 12, No. 2, Autumn and Winter 2025

List of articles

Title	Page
Output Voltage Indirect Control of DC-DC Boost Converter in the Continuous Conduction Mode using Robust Passivity-based Controller and Cascaded Closed-Loop PI Controller Authors: Mohammad Hadi Molaei Ardakani, Amirhossein Rajaei	5
Automated Multi-Parametric Analysis of Brain Lesions Over Time: A Detailed Deep Learning Framework for Quantitative Characterization Authors: Mahdi Bashiri Bawil, Mousa Shamsi, Abolhassan Shakeri Babil	29
Drift Detection and Compensation in Semiconductor Gas Sensors Using Lightweight Deep Learning Models Deployable on the Edge Authors: Amire Seyedfaraji	47
Optimization of sigma-delta modulator for medical applications Authors: Yousef Belghisaza, Khalil Monfaredi, Mousa Yousefi	73
Robust Adaptive Fuzzy Sliding Mode Control for Synchronization of Unknown Noncanonical Chaotic Systems Authors: Mohammad Safari Souri, Seyed Kamaledin Mousavi Mashhadi, Mohammad Fiuzy	87
Hybrid Deep–Texture Feature Fusion Network for Robust Melanoma Detection in Dermoscopic Images Authors: Nafiseh Gholami, Mansoor Zeinali	109



Sahand University
of Technology

DOR:

[20.1001.1.23223146.1405.12.2.1.0](https://doi.org/10.1001.1.23223146.1405.12.2.1.0)

**Journal of Nonlinear
Systems in Electrical
Engineering**

Vol. 12, No. 2

Autumn and Winter 2025

ISSN: 2322 – 3146

<http://jnsee.sut.ac.ir>

Output Voltage Indirect Control of DC-DC Boost Converter in the Continuous Conduction Mode using Robust Passivity-based Controller and Cascaded Closed-Loop PI Controller

Mohammad Hadi Molaei Ardakani, Amirhossein Rajaei *

Department of Electrical Engineering, Shiraz University of Technology, Shiraz, Iran

* Corresponding author email: a.rajaei@sutech.ac.ir

Abstract

This paper presents a robust hybrid controller based on passivity-based control (PBC) for output voltage regulation of a DC-DC boost converter operating in Continuous Conduction Mode (CCM). The proposed scheme integrates PBC within a cascade structure featuring a PI voltage loop to mitigate the limitations of individual methods. Due to the non-minimum phase nature of the boost converter, voltage regulation is achieved indirectly via inductor reference current tracking. This reference current is generated by the outer PI loop, while the inner PBC loop ensures stability and fast dynamic performance in the presence of disturbances and parametric uncertainties. System dynamic equations are derived using an averaged model that accounts for parasitic elements, and the controller is designed based on passivity stability theory. To validate the proposed method, a laboratory prototype was implemented, and the controller's performance was evaluated under five distinct scenarios, including step changes in reference voltage, load variations, input voltage fluctuations, and parameter uncertainties. Simulation and experimental results demonstrate significant improvements in stability, dynamic response, and steady-state error reduction compared to a pure passivity-based controller, confirming the robustness and effectiveness of the proposed hybrid approach under various operating conditions.

Keywords

Boost Converter; Passivity-based Control; Cascade Control; Robust Stability

1. Short Introduction

DC-DC converters play a vital role in modern technologies such as electric vehicles due to their high efficiency. However, the limitations of classical controllers in handling parametric variations have led to the development of advanced control strategies such as sliding mode control. While these methods address certain challenges, they do not always guarantee the inherent stability of nonlinear systems. Consequently, Passivity-Based Control (PBC) has emerged as an efficient solution for voltage regulation owing to its design simplicity and robustness. Furthermore, numerous studies have integrated PBC with other control techniques to enhance the performance of energy storage systems.

2. Proposed Work

To address the inherent non-minimum phase characteristics and stability challenges of DC-DC boost converters, this study proposes a robust hybrid control strategy that regulates the output voltage indirectly through inductor current tracking. The system dynamics are modeled using the Euler-Lagrange method, incorporating parasitic elements such as equivalent series resistances and semiconductor voltage drops to ensure a realistic representation. The control architecture integrates a Passivity-Based Controller (PBC) within a cascaded structure featuring a Closed-Loop PI (CCLPI) voltage regulator. In this configuration, the inner PBC loop utilizes energy shaping and damping injection principles to guarantee global asymptotic stability and fast dynamic response, while the outer PI loop generates the reference current to eliminate steady-state errors caused by model inaccuracies or load variations. Theoretical analysis based on Lyapunov stability theory confirms that the system maintains Input-to-State Stability (ISS) even in the presence of bounded parameter uncertainties. To validate this approach, a laboratory prototype was built and several tests were carried out. Experimental and simulation results across five scenarios, including step changes in reference voltage, load variations, input voltage fluctuations, and parameter uncertainties, demonstrate the superiority of the proposed CCLPI-PBC over standard PBC. Specifically, the proposed method successfully rejected severe disturbances, such as a 25% drop in input voltage and significant load changes, under conditions where the standard PBC failed to maintain regulation. Furthermore, sensitivity analysis revealed that under a drastic reduction in inductance from 10mH to 1mH, the hybrid controller reduced the steady-state error from 2.55V to a negligible 0.01V, confirming its robustness and precise tracking capabilities.

3. Conclusion

This study developed a hybrid CCLPI-PBC scheme to overcome the non-minimum phase challenges of boost converters via indirect current tracking. Experimental results confirm that, unlike classical PBC, the proposed method eliminates steady-state errors under severe fluctuations and maintains stability against significant parametric uncertainties, such as a reduction in inductance. Considering implementation simplicity and high robustness, this approach offers an efficient industrial solution for voltage-sensitive applications.

کنترل غیرمستقیم ولتاژ خروجی مبدل DC-DC افزاینده در حالت هدایت پیوسته با استفاده از کنترل کننده مقاوم مبتنی بر غیرفعال بودن و کنترل کننده PI حلقه بسته آشناری

محمد هادی مولایی اردکانی^۱، امیر حسین رجایی^{۲*}

^۱ دانشجوی دکتری، دانشکده مهندسی برق، دانشگاه صنعتی شیراز، شیراز، ایران

^۲ دانشیار، دانشکده مهندسی برق، دانشگاه صنعتی شیراز، شیراز، ایران

* آدرس پست الکترونیکی نویسنده مسئول: a.rajaei@sutech.ac.ir



دانشگاه صنعتی شیراز

DOR:

20.1001.1.23223146.1405.12.2.1.0

نشریه علمی-فصلنامه‌ای «مهندسی برق»

دوره ۱۲ - شماره ۲

پاییز و زمستان ۱۴۰۴

صفحات ۵ الی ۲۸

ISSN: 2322-3146

http://jnsee.sut.ac.ir

تاریخ پذیرش: ۱۴۰۴/۱۱/۱۸

تاریخ بازنگری: ۱۴۰۴/۱۰/۱۴ و ۱۴۰۴/۱۱/۱۶

تاریخ ارسال: ۱۴۰۴/۹/۱۰

چکیده

واژه‌های کلیدی

مبدل افزاینده

کنترل مبتنی بر رویکرد انفعالی

کنترل آشناری

پایداری مقاوم

در این مقاله، یک کنترل کننده ترکیبی مقاوم مبتنی بر رویکرد انفعالی برای تنظیم ولتاژ خروجی مبدل DC-DC افزاینده در حالت هدایت پیوسته ارائه شده است. طرح پیشنهادی، کنترل کننده مبتنی بر غیرفعال بودن (PBC) را در یک ساختار آشناری با حلقه‌های کنترلی PI تودرتو ادغام می‌کند تا کاستی‌های هر دو روش را پوشش دهد. با توجه به ماهیت غیرمینیمم‌فاز مبدل بوست، تنظیم ولتاژ به صورت غیرمستقیم و از طریق ردیابی جریان مرجع سلف انجام می‌شود. جریان مرجع توسط حلقه بیرونی PI تولید شده و حلقه درونی PBC، پایداری و عملکرد دینامیکی را در حضور اغتشاشات و عدم قطعیت‌های پارامتری تضمین می‌کند. روابط دینامیکی سیستم مبتنی بر مدل متوسط‌گیری شده با در نظرگیری المان‌های پارازیتی استخراج و کنترل کننده بر مبنای نظریه پایداری انفعالی طراحی شده است. برای اعتبارسنجی، یک نمونه آزمایشگاهی ساخته شده و عملکرد کنترل کننده پیشنهادی در پنج سناریوی مختلف شامل تغییرات پله‌ای ولتاژ مرجع، تغییرات بار، تغییرات ورودی و تغییرات پارامترهای مبدل، مورد ارزیابی قرار گرفته است. نتایج شبیه‌سازی و آزمایشگاهی، بهبود چشمگیر در پایداری، پاسخ دینامیکی سریع‌تر و کاهش خطای حالت ماندگار را در مقایسه با کنترل کننده انفعالی خالص نشان می‌دهند و بر مقاومت و کارایی روش ترکیبی پیشنهادی در شرایط عملیاتی مختلف تأکید دارند.

۱- مقدمه

امروزه، اکثر دستگاه‌های الکترونیکی به یک منبع تغذیه قابل اعتماد نیاز دارند. برای تأمین این توان، معمولاً از مبدل‌های الکترونیک قدرت از جمله مبدل‌های DC-DC استفاده می‌شود. ساختار این مبدل‌ها را می‌توان بسته به نیازهای کاربردی، به صورت ایزوله (افزاینده و کاهنده) یا غیرایزوله (افزاینده و کاهنده) انتخاب و طراحی کرد. مبدل‌های DC-DC کاربردهای گسترده‌ای در زمینه‌های مختلف، از جمله خودروهای الکتریکی، ریز شبکه‌ها، سیستم‌های فتوولتائیک و بسیاری از فناوری‌های نوظهور دیگر پیدا کرده‌اند [۱-۴]. این مبدل‌ها به دلیل راندمان بالا و پاسخ گذرای سریع، بسیار مورد توجه قرار گرفته‌اند [۵-۶]. در خصوص کنترل ولتاژ و جریان این مبدل‌ها روش‌های کنترلی متنوعی پیشنهاد شده‌اند. بعنوان نمونه، روش کنترل کلاسیک گزینه‌ای رایج است، اما این روش اغلب برای تضمین تنظیم ولتاژ و پایداری سیستم در برابر تغییر پارامترها کافی نیست. لذا، برای غلبه بر این محدودیت‌ها، چندین راه کار کنترل پیشرفته توسعه یافته‌اند [۷-۱۰]. روش‌های کنترلی مختلفی برای حفظ ولتاژ خروجی مبدل‌ها، به ویژه در سیستم‌هایی که با بارهای توان ثابت کار می‌کنند (مانند اینورترها) اعمال شده‌اند. به عنوان مثال، خطی‌سازی فیدبک [۱۱] و کنترل مد لغزشی (SMC) [۱۲] در چنین مواردی به کار گرفته شده‌اند. اگرچه این روش‌ها می‌توانند مسائل خاص را حل کنند، اما حفظ ویژگی‌های پایداری ذاتی سیستم غیرخطی را تضمین نمی‌کنند. در خانواده کنترل کننده‌های غیرخطی، کنترل کننده مبتنی بر غیرفعال بودن (PBC) گسترش زیادی یافته‌اند. این رویکرد به دلیل رویه طراحی ساده و ویژگی‌های مقاوم قوی، جذابیت ویژه‌ای دارند.

کنترل کننده مبتنی بر غیر فعال بودن بطور موثر در مبدل‌های DC-DC برای تضمین پایداری سیستم، تنظیم ولتاژ و ردیابی ولتاژ خروجی اعمال شده است [۱۳-۱۴]. علاوه بر این در [۱۵]، یک طرح کنترل مبتنی بر PBC برای اطمینان از تزریق جریان ثابت به بانک باتری و تنظیم ولتاژ باتری در سطح مرجع مشخص، پیشنهاد شده است. مرجع [۱۶] نیز یک کنترل کننده PBC تطبیقی را پیشنهاد می‌کند که نه تنها تجزیه و تحلیل پایداری کاملی از مبدل ارائه می‌دهد، بلکه تنظیم ولتاژ خروجی قابل اعتمادی را در یک مبدل افزاینده-کاهنده با بار توان ثابت نیز به دست می‌آورد.

در برخی مطالعات، کنترل کننده مبتنی بر PBC با سایر استراتژی‌های کنترلی ترکیب شده است تا عملکرد آن بهبود یابد. به عنوان مثال در [۱۷]، یک چارچوب کنترلی که PBC را با SMC ادغام می‌کند که هدف آن دستیابی به تنظیم دقیق ولتاژ خروجی و در عین حال تضمین خطای حالت پایدار صفر است. علاوه بر این، یک کنترل کننده مؤثر باید پایداری را تحت شرایط عملیاتی مختلف، از جمله تغییرات بار، تغییرات ولتاژ مرجع، نوسانات تغذیه ورودی و اختلالات سیستم حفظ کند [۱۸].

این مقاله، روش طراحی کنترل کننده PBC را ارائه می‌دهد و تجزیه و تحلیل جامعی از عملکرد آن تحت شرایط مختلف، از جمله نوسانات ولتاژ ورودی، تغییرات ولتاژ مرجع، تغییرات ولتاژ خروجی و عدم قطعیت‌های پارامتر در مبدل ارائه می‌دهد. نتایج نشان می‌دهد که اگرچه PBC ویژگی‌های امیدوار کننده‌ای ارائه می‌دهد اما محدودیت‌های خاصی نیز دارد. برای غلبه بر این معایب، یک کنترل کننده حلقه بسته آنباشی مبتنی بر کنترل PI با PBC ادغام شده، که منجر به توسعه کنترل کننده ترکیبی پیشنهادی شده است. نتایج شبیه‌سازی و آزمایشگاهی ارائه شده و ارزیابی مقایسه‌ای بین دو کنترل کننده انجام شده است. لازم بذکر است نوآوری اصلی این پژوهش، ارائه یک راهکار کنترل غیرمستقیم ولتاژ مبتنی بر استراتژی جریان محور^۱ است. برخلاف روش‌های کنترل مستقیم ولتاژ که در مبدل‌های افزاینده با چالش ناپایداری دینامیک‌های صفر^۲ ناشی از رفتار فاز غیرمینیمم مواجه هستند، روش پیشنهادی با تنظیم دقیق جریان سلف (که متغیری با فاز مینیمم است)، ولتاژ خروجی را به صورت غیرمستقیم و پایدار کنترل می‌کند.


¹ Current-Mode Control² Zero Dynamics

این مقاله شامل بخش‌های زیر است:

- بخش ۱. بخش مقدمه که مورد بررسی قرار گرفت.
- بخش ۲. مدل‌سازی ریاضی مبدل بوست با در نظر گرفتن المان‌های پارازیتی و تلفاتی که این مدل‌سازی بر پایه استفاده از تابع تلفات رایلی انجام گرفته است.
- بخش ۳. در این بخش طراحی کنترل کننده بر پایه روش پیشنهادی برای مبدل بوست انجام گرفته است.
- بخش ۴. تحلیل پایداری مقاوم در حضور عدم قطعیت‌های پارامترهای مبدل را بررسی می‌کند.
- بخش ۵. نتایج شبیه‌سازی و آزمایشگاهی روش کنترلی پیشنهادی و پیاده‌سازی عملیات آن را ارائه می‌دهد.
- بخش ۶. در این بخش نتیجه‌گیری مقاله آورده شده و بخش ۷. شامل مراجع می‌باشد.

۲- مدل‌سازی ریاضی مبدل افزایشده بر مبنای معادلات دینامیکی لاگرانژ

شکل ۱ مبدل افزایشده متصل به یک بار الکتریکی را نشان می‌دهد، که در آن کلیه المان‌های تلفاتی و پارازیتی مربوط به هر عنصر مدل شده‌اند.



شکل ۱: مبدل افزایشده با در نظر گرفتن المان‌های پارازیتی و تلفاتی

برای استخراج مدل دینامیکی مبدل در ابتدا بایستی رویکرد مدل‌سازی معادلات دینامیکی لاگرانژ را ارائه دهیم، که ویژگی‌های فیزیکی مرتبط با مبدل افزایشده را تعیین می‌کند [۱۹]. بنابراین خواهیم داشت:

$$\frac{d}{dt} \left(\frac{\partial f}{\partial \dot{q}} \right) - \frac{\partial f}{\partial q} + \frac{\partial D}{\partial \dot{q}} = F \quad (1)$$

$\dot{q}$ بردار جریان، q بردار بار الکتریکی، تابع اسکالر f لاگرانژین سیستم و تابع $D(\dot{q})$ تابع تلفات رایلی است. تابع اسکالر f از تفاضل بین کوانرژی مغناطیسی مدار $T(\dot{q}, q)$ و انرژی میدان الکتریکی $V(q)$ بدست می‌آید. بردار $F_q = (F_{q1}, \dots, F_{qn})$ مجموعه‌ای از توابع تعمیم یافته مربوط به منابع است. لذا خواهیم داشت:

$$f(\dot{q}, q) = T(\dot{q}, q) - V(q) \quad (2)$$

$$\frac{d}{dt} \left(\frac{\partial T}{\partial \dot{q}} \right) - \frac{\partial T}{\partial q} + \frac{\partial V}{\partial q} = - \frac{\partial D}{\partial \dot{q}} + F_q \quad (3)$$

برای استخراج معادلات غیر خطی مبدل افزایشده که در شکل ۱ نشان داده شده است نخست تابع انرژی، کوانرژی و تابع رایلی محاسبه می‌شود. این معادلات در رابطه (۴) آمده است.

$$\begin{aligned}
T_{\mu}(\dot{q}_L) &= \frac{1}{2} \cdot L \cdot (\dot{q}_L)^2 \\
V_{\mu}(q_c) &= \frac{1}{2c} \cdot q_c^2 \\
D_{\mu}(\dot{q}_L, \dot{q}_c) &= \frac{1}{2} \cdot r_L \cdot (\dot{q}_L)^2 + \frac{1}{2} \cdot r_C \cdot (\dot{q}_c)^2 + \frac{1}{2} [\mu \cdot r_{DS} + (1 - \mu) \cdot R_F] \cdot (\dot{q}_L)^2 \\
&+ \frac{1}{2} \cdot R \cdot [(1 - \mu) \cdot \dot{q}_L - \dot{q}_c]^2 F_{qL}^{\mu} = E - (1 - \mu) \cdot V_F \\
F_{qC}^{\mu} &= 0
\end{aligned} \quad (۴)$$

رابطه (۴) نشان می‌دهد در فرآیند کلید زنی تنها تابع رایلی تغییر کرده و ساختار تلفات سیستم تنها توسط μ ($\mu \in [0,1]$) تأثیر می‌پذیرد. بنابراین با ترکیب روابط (۲) تا (۴) معادلات غیر خطی مبدل افزاینده بدست می‌آید.

$$\begin{aligned}
L\ddot{q}_L &= -R(1 - \mu) \cdot [(1 - \mu) \cdot \dot{q}_L - \dot{q}_c] + E - (1 - \mu) \cdot V_F \\
&- [r_L + \mu \cdot r_{DS} + (1 - \mu) \cdot R_F] \cdot \dot{q}_L \\
\frac{q_c}{c} &= R \cdot [(1 - \mu) \cdot \dot{q}_L - \dot{q}_c] - r_C \cdot \dot{q}_c
\end{aligned} \quad (۵)$$

با تغییر متغیر $Z_1 = \dot{q}_L$ و $Z_2 = \frac{q_c}{c}$ رابطه (۵) بصورت رابطه (۶) بازنویسی می‌شود.

$$\begin{aligned}
\dot{z}_1 &= -\frac{1}{L} \cdot r \cdot Z_1 - (1 - \mu) \cdot \frac{R}{L \cdot (r_C + R)} \cdot Z_2 + \frac{E}{L} - (1 - \mu) \cdot \frac{V_F}{L} \\
\dot{z}_2 &= (1 - \mu) \cdot \frac{R}{(R + r_C) \cdot C} \cdot Z_1 - \frac{1}{(R + r_C) \cdot C} \cdot Z_2 \\
r &= r_L + \mu \cdot r_{DS} + (1 - \mu) \cdot R_F + (1 - \mu)^2 \cdot \left(\frac{r_C R}{r_C + R} \right)
\end{aligned} \quad (۶)$$

شایان ذکر است که در استخراج معادلات فوق، متغیر μ به عنوان سیکل پیوسته^۱ در بازه $[0,1]$ در نظر گرفته شده است. بنابراین، مدل دینامیکی حاصل از روش اویلر-لاگرانژ (رابطه ۶)، معادل با مدل فضای حالت متوسط گیری شده^۲ مبدل بوده و رفتار میانگین سیستم را در فرکانس‌های پایین (بدون در نظر گرفتن رپل‌های فرکانس سوئیچینگ) توصیف می‌کند (مدل اویلر-لاگرانژ همان خاصیت مدل متوسط را دارد).

Z_1 متوسط جریان ورودی (جریان سلف) و Z_2 متوسط ولتاژ خروجی (ولتاژ خازن) مبدل افزاینده می‌باشند. همچنین معادلات (۶) را می‌توان به فرم ماتریسی، مطابق با رابطه (۷) بازنویسی کرد.

$$D\dot{Z} + (1 - \mu) \cdot JZ + \mathfrak{R}Z = \varepsilon \quad (۷)$$

که:

$$\begin{aligned}
D &= \begin{bmatrix} L & 0 \\ 0 & \frac{C(r_C + R)}{R} \end{bmatrix}, J = \begin{bmatrix} 0 & \frac{R}{R + r_C} \\ -1 & 0 \end{bmatrix}, \mathfrak{R} = \begin{bmatrix} r & 0 \\ 0 & \frac{1}{R} \end{bmatrix}, \varepsilon \\
&= \begin{bmatrix} E - (1 - \mu)V_F \\ 0 \end{bmatrix}
\end{aligned} \quad (۸)$$

مدل فضای حالت مبدل افزاینده با بهره‌گیری از رهیافت اویلر-لاگرانژ و با لحاظ نمودن تمامی المان‌های پارازیتی و تلفاتی استخراج گردید. این پارامترها شامل مقاومت‌های سری معادل سلف و خازن، مقاومت هدایت و افت ولتاژ مستقیم دیود و مقاومت درین-سورس ماسفت می‌باشند. با استناد به این مدل دقیق، در ادامه روند طراحی کنترل کننده پیشنهادی تشریح می‌شود.

^۱ Continuous Duty Ratio

^۲ State-Space Averaged Model

۳- طراحی کنترل کننده مبتنی بر انفعال

برای طراحی کنترل کننده PBC، متغیرهای خطا بصورت $\tilde{Z}_1 = Z_1 - Z_{1d}$ و $\tilde{Z}_2 = Z_2 - Z_{2d}$ تعریف می شوند، که با قرار گیری در رابطه (۷) خواهیم داشت:

$$D\dot{\tilde{Z}} + (1 - \mu).J\tilde{Z} + \mathfrak{R}\tilde{Z} = \varepsilon - (D\dot{Z}_d + (1 - \mu).JZ_d + \mathfrak{R}Z_d) \quad (9)$$

روش کنترل مبتنی بر انفعال (PBC) بر دو اصل بنیادین «شکل دهی انرژی» و «تزریق میرایی» استوار است. هدف اصلی در این روش، اصلاح انرژی سیستم حلقه بسته به گونه ای است که دارای یک کمینه سراسری در نقطه تعادل مطلوب (Z_d) باشد. از آنجا که مدل دینامیک خطای سیستم در رابطه (۷) استخراج شد، برای تضمین همگرایی خطاها به صفر ($\tilde{Z} \rightarrow 0$) و حذف نوسانات لازم است اتلاف انرژی مجازی (میرایی) به سیستم تزریق شود. لذا با افزودن ماتریس میرایی تزریقی $\mathfrak{R}_d$ به طرفین رابطه (۹) دینامیک خطا، معادله ساختار کنترل کننده به صورت رابطه (۱۰) بازنویسی می شود. در واقع جمله $\mathfrak{R}_d \tilde{Z}$ همان اصطکاک مجازی است که اضافه شده تا خطاها را میرا سازد.

$$\psi = \varepsilon - (D\dot{Z}_d + (1 - \mu).JZ_d + \mathfrak{R}Z_d - \mathfrak{R}_d \tilde{Z}) \quad (10)$$

$$\mathfrak{R}_d = \begin{bmatrix} r_{d1} & 0 \\ 0 & r_{d2} \end{bmatrix}, \quad r_{d1} > 0 \text{ \& } r_{d2} > 0 \quad (11)$$

ماتریس $\mathfrak{R}_d$ به نام ماتریس تزریق میرایی^۱ شناخته می شود. این ماتریس دارای ویژگی های زیر است:
۱. یک ماتریس قطری و متقارن است.

۲. باید معین مثبت^۲ باشد. یعنی تمام درایه های روی قطر اصلی آن باید مثبت باشند ($\mathfrak{R}_d > 0$).

۳. این ماتریس وجود خارجی (سخت افزاری) ندارد، بلکه مقاومت های مجازی هستند که در کد میکروکنترلر اضافه می شود. این مقاومت های مجازی، انرژی خطای سیستم ($\tilde{Z}$) را تلف می کنند تا خطا سریعاً به صفر میل کند.
همچنین برای پایداری ψ از تابع لیاپانوف استفاده می شود. تابع لیاپانوف به صورت زیر در نظر گرفته شده است.

$$H_d = \frac{1}{2} \tilde{Z}^T D \tilde{Z} > 0; \forall \tilde{Z} \neq 0 \quad (12)$$

مشتق زمانی H_d بصورت زیر تعریف می شود:

$$\dot{H}_d = \frac{1}{2} \dot{\tilde{Z}}^T D \tilde{Z} + \frac{1}{2} \tilde{Z}^T D \dot{\tilde{Z}} = - \left((r + r_{d1}) \tilde{Z}_1^2 + \left(\frac{1}{R} + r_{d2} \right) \tilde{Z}_2^2 \right) < 0; \forall \tilde{Z} \neq 0 \quad (13)$$

$$\lim_{t \rightarrow \infty} H_d = 0 \Rightarrow \lim_{t \rightarrow \infty} \tilde{Z} = 0$$

در این حالت، علاوه بر تزریق میرایی به جریان سلف (r_{d1})، به ولتاژ خازن نیز میرایی مجازی (r_{d2}) تزریق شده است. این عمل باعث می شود سرعت همگرایی خطا به صفر در هر دو متغیر حالت (جریان و ولتاژ) افزایش یابد و پایداری سیستم قوی تر شود. عبارت دیگر مشتق انرژی منفی بوده ($\dot{H}_d < 0$) یعنی انرژی خطا دائماً در حال کاهش است و لذا خطا بسمت صفر میل می نماید.

لازم بذکر است در مبدل های افزاینده، معمولاً تزریق میرایی روی خازن (r_{d2}) چالش برانگیز است. لذا برای طراحی کنترل کننده PBC برای مبدل افزاینده، معمولاً $r_{d2} = 0$ در نظر گرفته شود تا استخراج قانون کنترلی و پیاده سازی ساده تر و از پیچیدگی معادلات جبری جلوگیری شود. حال اگر $r_{d2} > 0$ در نظر بگیرید، مشتق لیاپانوف صحیح است و پایداری اثبات می شود، اما ممکن است معادله نهایی که برای محاسبه سیکل وظیفه (μ) بدست می آید بسیار پیچیده شود یا نیاز به حل معادلات جبری دشوار داشته

¹ Damping Injection Matrix

² Positive Definite

باشد. بنابراین در اینجا هدف طراحی قانون کنترلی به گونه‌ای است که قید $\psi = 0$ برقرار گردد. عبارت دیگر وقتی $\psi = 0$ است، تنها نیروی فعال در سیستم، نیروی اصطکاک مجازی ($\mathfrak{R}_d$) است. این اصطکاک دائماً انرژی خطای سیستم را جذب و تلف می‌کند. چون هیچ نیروی دیگری (اغتشاش) وجود ندارد که انرژی تزریق کند، انرژی خطا نهایتاً تمام و سیستم دقیقاً در نقطه تعادل یعنی خطای صفر می‌ایستد.

$$D \dot{Z}_d + (1 - \mu).JZ_d + \mathfrak{R}_d Z_d - \mathfrak{R}_d \tilde{Z} = \varepsilon \quad (14)$$

که:

$$\begin{aligned} & \begin{bmatrix} L & 0 \\ 0 & \frac{C(r_c + R)}{R} \end{bmatrix} \begin{bmatrix} \dot{Z}_{1d} \\ \dot{Z}_{2d} \end{bmatrix} + (1 - \mu) \begin{bmatrix} 0 & \frac{R}{R + r_c} \\ -1 & 0 \end{bmatrix} \begin{bmatrix} Z_{1d} \\ Z_{2d} \end{bmatrix} \\ & + \begin{bmatrix} r & 0 \\ 0 & \frac{1}{R} \end{bmatrix} \begin{bmatrix} Z_{1d} \\ Z_{2d} \end{bmatrix} - \begin{bmatrix} r_{d1} & 0 \\ 0 & 0 \end{bmatrix} \begin{bmatrix} Z_1 - Z_{1d} \\ Z_2 - Z_{2d} \end{bmatrix} \\ & = \begin{bmatrix} E - (1 - \mu)V_F \\ 0 \end{bmatrix} \end{aligned} \quad (15)$$

یا می‌توان نوشت:

$$\begin{aligned} L \dot{Z}_{1d} + (1 - \mu) \frac{R}{R + r_c} Z_{2d} + r.Z_{1d} - (Z_1 - Z_{1d})r_{d1} &= E - (1 - \mu)V_F \\ \frac{C(r_c + R)}{R} \dot{Z}_{2d} - (1 - \mu)Z_{1d} + \frac{1}{R} Z_{2d} &= 0 \end{aligned} \quad (16)$$


دو موضوع مهم در این مبحث وجود دارد که باید به آن پرداخت. اول آنکه اگر ولتاژ خازن به عنوان خروجی مبدل Boost در نظر گرفته شود سیستم غیر مینیم فاز خواهد شد. دوم آنکه اگر جریان ورودی به عنوان خروجی مبدل در نظر گرفته شود سیستم مینیم فاز خواهیم داشت. بنابراین ولتاژ خروجی این مبدل بطور غیر مستقیم با ردیابی جریان مرجع سلف کنترل می‌شود. حال اگر $Z_{1d} = I_d$ در نظر گرفته شود با این هدف که ولتاژ خروجی بتواند ولتاژ مرجع را دنبال کند به کنترل کننده مطلوب خود دست یافته‌ایم و ولتاژ خروجی را بصورت غیرمستقیم کنترل نماییم، لذا برای رسیدن به این یک هدف قانون کنترلی برای سیگنال PWM محاسبه می‌شود. بنابراین با فرض که $Z_{1d} = I_d$ باشد در ابتدا Z_{2d} از رابطه نخست مجموعه معادلات (۱۶) را بدست می‌آوریم.

$$Z_{2d}(t) = \frac{[E - (1 - \mu)V_F] + (Z_1 - I_d)r_{d1} - r.I_d}{(1 - \mu) \frac{R}{R + r_c}} \quad (17)$$

با قرار دادن رابطه (۱۷) در معادله دوم (۱۶) قانون کنترلی برای μ که برای ساخت سیگنال PWM استفاده می‌شود بدست می‌آید.

$$\mu = \frac{(1-\mu) \cdot \left(\frac{R}{R+r_c}\right)^2}{\underbrace{c[E + (Z_1 - I_d) \cdot r_{d1}]}_{F0}} \left[\underbrace{(1-\mu)^2 \cdot I_d}_{F1} - \underbrace{\frac{E + (Z_1 - I_d) \cdot r_{d1} - (1-\mu)V_F}{R \cdot \frac{R}{R+r_c}}}_{F2} - \underbrace{\frac{r_{d1}C}{L} \cdot \left[\frac{E - (1-\mu) \left[Z_2 \frac{R}{R+r_c} + V_F \right] - r \cdot I_d}{\left(\frac{R}{R+r_c}\right)^2} \right]}_{F3} \right] \quad (18)$$

قانون کنترلی μ بدست آمده از رابطه (۱۸) را بشکل زیر می توان ترسیم کرد.



شکل ۲: محاسبه قانون کنترلی μ

رابطه (۱۸) دینامیک تغییرات سیگنال کنترلی μ را بر حسب پارامترهای مدار و جریان I_d بیان می کند. برای پیاده سازی عملی این معادله دیفرانسیل، از ساختار کنترلی نمایش داده شده در شکل (۲) استفاده شده است. در این ساختار، عبارت های پیچیده سمت راست معادله (۱۸) به صورت بلوک های محاسباتی مجزا (F_0, F_1, F_2, F_3) مدل سازی شده اند. ورودی این بلوک ها شامل مقادیر ثابت و متغیرهای حالت سیستم بوده و خروجی آن ها پس از اعمال عملیات جبری، مشتق قانون کنترلی را می سازد. لذا، با استفاده از بلوک انتگرال گیر ($\frac{1}{s}$)، مقدار لحظه ای μ برای اعمال به سیستم استخراج می گردد.

اکنون می بایست ارتباط بین $Z_1 = I_d$ و $Z_2 = V_d = V_{ref}$ مشخص شود. با فرض ثابت بودن $\mu = U$ و همچنین با استفاده از معادله دوم رابطه (۶) خواهیم داشت:

$$\begin{cases} \dot{Z}_2 = 0 \\ Z_1 = I_d \\ Z_2 = V_d \end{cases} \Rightarrow (1-U) \cdot \frac{R}{(R+r_c) \cdot C} \cdot I_d - \frac{1}{(R+r_c) \cdot C} \cdot V_d = 0 \Rightarrow 1-U = \frac{V_d}{R \cdot I_d} \quad (19)$$

همچنین با صفر قرار دادن معادله اول رابطه (۶) داریم:

$$\dot{z}_1 = 0 \Rightarrow -\frac{r}{L} \cdot I_d - (1-U) \cdot \frac{R}{L \cdot (r_c + R)} \cdot V_d + \frac{E}{L} - (1-U) \cdot \frac{V_F}{L} = 0 \quad (20)$$

حال بجای $(1-U)$ در رابطه (۲۰)، رابطه (۱۹) را جایگذاری کرده و خواهیم داشت:

$$-\frac{r}{L} \cdot I_d - \frac{R \cdot V_d}{L \cdot (r_c + R)} \cdot \frac{V_d}{R \cdot I_d} + \frac{E}{L} - \frac{V_F}{L} \cdot \frac{V_d}{R \cdot I_d} = 0 \quad (21)$$


رابطه (۲۱) را می توان بصورت رابطه (۲۲) بازنویسی کرد، لذا خواهیم داشت:

$$\begin{aligned} -r \cdot I_d^2 + E \cdot I_d - K_{load} &= 0 \\ K_{load} &= \frac{V_d^2}{r_c + R} + \frac{V_F \cdot V_d}{R} \end{aligned} \quad (22)$$

K_{load} نمایانگر توان مصرفی بار و تلفات دیود است. معادله (۲۲) یک معادله درجه دوم بر حسب I_d است، که می بایست آنرا حل و رابطه I_d بر حسب V_d را محاسبه نمود. همچنین پاسخ صحیح ریشه ای است که دارای علامت منفی پشت رادیکال است تعیین نمود.

$$I_d = \frac{E - \sqrt{E^2 - 4rK_{load}}}{2r} \quad (23)$$

بنابراین با توجه به رابطه (۲۳)، I_d بر حسب V_d ، ولتاژ ورودی و سایر پارامترها محاسبه گردیده تا مشکل حلقه جبری مرتفع شود. کنترل کننده PBC علیرغم مزایایی که دارد، با محدودیت هایی روبروست. به منظور غلبه بر این کاستی ها و بهبود عملکرد مبدل افزاینده در شرایط کاری مختلف، از یک ساختار کنترلی آبخاری مبتنی بر PI استفاده شده است که شامل دو حلقه کنترلی جریان داخلی و ولتاژ خارجی می باشد. شکل ۳ شماتیک کنترل کننده پیشنهادی را نشان می دهد که حاصل ترکیب دو استراتژی کنترلی مذکور است. همان طور که در بلوک دیاگرام مشاهده می شود، این ساختار با بهره گیری از روابط ریاضی و بدون نیاز به حسگرهای اضافی، خطای جریان I_d را جبران می کند. در واقع، این روش با کمترین پیچیدگی محاسباتی، تلفیقی هوشمندانه از کنترل کننده های PI آبخاری و PBC را ارائه می دهد که منجر به بهبود چشمگیر پاسخ دینامیکی سیستم می گردد.



شکل ۳: کنترل کننده آبخاری مبتنی بر PI

لازم به ذکر است که تحلیل پایداری ارائه شده در این بخش، پایداری مجانبی حلقه داخلی سیستم (کنترل کننده PBC) را با فرض ثابت بودن سیگنال مرجع تضمین می کند. پایداری ساختار کلی آبخاری بر اساس اصل جداسازی زمانی^۱ استوار است. در این طراحی، پهنای باند حلقه خارجی ولتاژ (PI) به مراتب کمتر از حلقه داخلی جریان انتخاب شده است. در نتیجه، دینامیک های ولتاژ نسبت به جریان بسیار کندتر عمل کرده و سیگنال مرجع جریان (I_d^*) از دیدگاه حلقه داخلی به صورت شبه ایستا^۲ دیده می شود که فرض های اثبات فوق را معتبر می سازد. نوآوری این مقاله، روش کنترلی مبتنی بر روش جریان محور می باشد.

۴- تحلیل پایداری مقاوم در حضور عدم قطعیت های پارامترها

با فرض اینکه مقادیر واقعی پارامترها (R, C) نسبت به مقادیر نامی استفاده شده در طراحی کنترل کننده (R_n, C_n) دارای انحراف باشند، این انحرافات به صورت کراندار تعریف می شوند:

$$\begin{aligned} C &= C_n + \Delta C & |\Delta C| &\leq \delta_C \\ \frac{1}{R} &= \frac{1}{R_n} + \Delta g & |\Delta g| &\leq \delta_G \end{aligned} \quad (24)$$

ΔC و Δg نشان دهنده خطای پارامتری و δ_C و δ_G کران های عدم قطعیت (مثلاً متناظر با ۲۰٪ تغییرات) هستند. معادلات دینامیکی خطای سیستم با در نظر گرفتن این عدم قطعیت ها به صورت زیر بازنویسی می شوند:

$$D_{act}\dot{Z} + [(1 - \mu)J + \Re_{act}]Z = \varepsilon \quad (25)$$

که:

$$\begin{aligned} D_{act} &= D_n + \Delta D \\ \Re_{act} &= \Re_n + \Delta \Re \end{aligned} \quad (26)$$

با جایگذاری رابطه (۲۶) در (۲۵) داریم:

$$(D_n + \Delta D)\dot{Z} + [(1 - \mu)J + (\Re_n + \Delta \Re)]Z = \varepsilon \quad (27)$$

جملاتی را که شامل Δ (عدم قطعیت) هستند به سمت راست تساوی منتقل می کنیم تا سمت چپ فقط شامل مدل نامی باشند.

$$\begin{aligned} D_n\dot{Z} + [(1 - \mu)J + \Re_n]Z &= \varepsilon + \psi_{TOTAL} \\ \psi_{TOTAL} &= -(\Delta DZ + \Delta \Re Z) \end{aligned} \quad (28)$$

هدف کنترل کننده PBC، شکل دهی به انرژی سیستم است به طوری که در حالت حلقه بسته، سیستم با یک ماتریس میرایی مطلوب ($\Re_d$) و در نقطه تعادل مطلوب (Z_d) کار کند. اگر سیستم بدون اغتشاش ($\psi = 0$) باشد، برای خطای $\tilde{Z} = Z - Z_d$ معادله زیر برقرار میگردد (تزریق میرایی $\Re_d$).

$$D_n\dot{\tilde{Z}} + [(1 - \mu)J + \Re_d]\tilde{Z} = 0 \quad (29)$$

در رابطه (۲۸) یک جمله مزاحم ψ_{TOTAL} در سمت راست وجود دارد. وقتی تفاضل وضعیت موجود (رابطه ۲۸) و وضعیت مطلوب محاسبه می شود، جمله اغتشاش ψ_{TOTAL} در معادله باقی می ماند. لذا معادله نهایی دینامیک خطا به صورت زیر در می آید:

$$D_n\dot{\tilde{Z}} + [(1 - \mu)J + \Re_d]\tilde{Z} = \psi_{TOTAL} \quad (30)$$

ψ_{TOTAL} بردار اغتشاش کلی است که از دو مولفه تشکیل شده است:

¹ Time-scale Separation

² Quasi-static

$$\psi_{TOTAL} = \psi_{LOAD} + \psi_{CAPACITOR} \quad (31)$$

I. اغتشاش ناشی از تغییر بار (ψ_{LOAD}): که مستقیماً به ولتاژ خروجی وابسته است:

$$\psi_{LOAD} = [0, -\Delta g \cdot Z_2]^T \quad (32)$$

II. اغتشاش ناشی از تغییر خازن ($\psi_{CAPACITOR}$): این جمله ناشی از تفاوت نرخ تغییرات ولتاژ در مدل واقعی و نامی است. با

تقریب خطی، می توان آن را به صورت یک اغتشاش وابسته به جریان خازن مدل کرد:

$$\psi_{CAPACITOR} \approx [0, -\frac{\Delta C}{C_n} \cdot i_C]^T \quad (33)$$

برای تحلیل پایداری، از تابع لیاپانوف مبتنی بر انرژی نامی استفاده می کنیم:

$$H_d = \frac{1}{2} \tilde{Z}^T D_n \tilde{Z} > 0; \forall \tilde{Z} \neq 0 \quad (34)$$

مشتق زمانی این تابع برابر است با:

$$\dot{H}_d = \frac{1}{2} \dot{\tilde{Z}}^T D_n \tilde{Z} + \frac{1}{2} \tilde{Z}^T D_n \dot{\tilde{Z}} \quad (35)$$

چون D_n ماتریس قطری و متقارن است (شامل L و C)، دو جمله با هم برابرند و داریم:

$$\dot{H}_d = \tilde{Z}^T (D_n \dot{\tilde{Z}}) \quad (36)$$

از رابطه نهایی دینامیک خطا یعنی رابطه (30) داریم:

$$D_n \dot{\tilde{Z}} = -[(1 - \mu)J + \mathfrak{R}_d] \tilde{Z} + \psi_{TOTAL} \quad (37)$$

با جایگذاری رابطه (37) در رابطه (36) خواهیم داشت:

$$\dot{H}_d = -\tilde{Z}^T (1 - \mu)J \tilde{Z} - \tilde{Z}^T \mathfrak{R}_d \tilde{Z} + \tilde{Z}^T \psi_{TOTAL} \quad (38)$$

J ماتریس پاد متقارن بوده لذا داریم:

$$\dot{H}_d = -\tilde{Z}^T \mathfrak{R}_d \tilde{Z} + \tilde{Z}^T \psi_{TOTAL} \quad (39)$$

باتوجه به اینکه که $\mathfrak{R}_d$ یک ماتریس است و محاسبات با ماتریس در نامساوی ها کاری دشوار است، لذا می بایست این عبارت

ماتریسی را به یک عبارت ساده تر تبدیل کنیم که فقط شامل اندازه خطا ($\|Z\|^2$) باشد. لذا از نامساوی معروف زیر استفاده می کنیم.

$$\lambda_{min}(\mathfrak{R}_d) \|Z\|^2 \leq \tilde{Z}^T \mathfrak{R}_d \tilde{Z} \leq \lambda_{max}(\mathfrak{R}_d) \|Z\|^2 \quad (40)$$

با ضرب در منفی، جهت نامساوی عوض خواهد شد لذا داریم:

$$-\lambda_{min}(\mathfrak{R}_d) \|Z\|^2 \geq -\tilde{Z}^T \mathfrak{R}_d \tilde{Z} \quad (41)$$

برای تخمین بدبینانه داریم:

$$\lambda_{min}(\mathfrak{R}_d) \|Z\|^2 \approx \tilde{Z}^T \mathfrak{R}_d \tilde{Z} \quad (42)$$

حال باید به محاسبه جمله $\tilde{Z}^T \psi_{TOTAL}$ پرداخت:

$$\psi_{TOTAL} = \psi_{LOAD} + \psi_{CAPACITOR} = [0, -\Delta g \cdot Z_2]^T + \left[0, -\frac{\Delta C}{C_n} \cdot i_c\right]^T \quad (43)$$

$$\tilde{Z}^T \psi_{TOTAL} = [\tilde{Z}_1 \quad \tilde{Z}_2] \psi_{TOTAL} = \tilde{Z}_2 \cdot \Delta g \cdot Z_2 + \tilde{Z}_2 \cdot \frac{\Delta C}{C_n} i_c$$

لذا به رابطه نهایی زیر خواهیم رسید:

$$\dot{H}_d = -\lambda_{min}(\mathfrak{R}_d) \|\tilde{Z}\|^2 + (\tilde{Z}_2 \cdot \Delta g \cdot Z_2 + \tilde{Z}_2 \cdot \frac{\Delta C}{C_n} i_c)$$

$$Dissipation Term = -\lambda_{min}(\mathfrak{R}_d) \|\tilde{Z}\|^2 \quad (44)$$

$$Perturbation Term = \left(\tilde{Z}_2 \cdot \Delta g \cdot Z_2 + \tilde{Z}_2 \cdot \frac{\Delta C}{C_n} i_c \right)$$

رابطه (۴۴) نرخ تغییرات زمانی تابع انرژی حلقه بسته ($\dot{H}_d$) را نشان می‌دهد. همان‌طور که مشاهده می‌شود، این عبارت از دو بخش تشکیل شده است. بخش اول که متناسب با مقدار ویژه ماتریس میرایی ($\mathfrak{R}_d$) و مجذور نرم خطا ($\|\tilde{Z}\|^2$) است، همواره معین منفی بوده و نقش اتلاف انرژی (را ایفا می‌کند. ترم دوم بیانگر اثرات نامعین عدم قطعیت‌های پارامتری (Δg و ΔC) است که ماهیت اغتشاشی دارد. شرط پایداری مقاوم بر این اساس استوار است که ترم اتلافی بر ترم اغتشاش غلبه کند. با توجه به اینکه ترم پایدارساز از مرتبه دوم خطا ($\|\tilde{Z}\|^2$) و ترم‌های اغتشاش عمدتاً از مرتبه اول خطا ($\|\tilde{Z}\|$) یا کران‌دار هستند، برای مقادیر بزرگ خطا، ترم منفی غالب خواهد شد. این ویژگی اثبات می‌کند که سیستم پیشنهادی دارای پایداری ورودی-به-حالت (ISS^1) است؛ بدین معنا که متغیرهای حالت حتی در حضور عدم قطعیت‌ها و اگرانداشته و خطای ردیابی در نهایت به یک همسایگی کوچک در اطراف مبدأ همگرا می‌شود. بنابراین برای تضمین پایداری، لازم است مشتق لیاپانوف منفی باشد ($\dot{H}_d < 0$) با در نظر گرفتن کران بالای اغتشاشات به صورت شرط پایداری $\|\psi_{TOTAL}\| \leq \delta \|\tilde{Z}\|$ بصورت زیر تحلیل می‌شود:

$$\dot{H}_d \leq -\lambda_{min}(\mathfrak{R}_d) \|\tilde{Z}\|^2 + \delta \|\tilde{Z}\| \quad (45)$$

از آنجا که ترم پایدارساز از مرتبه دوم نرم خطا (Quadratic) و ترم اغتشاش از مرتبه اول (Linear) است، برای مقادیر بزرگ خطا، ترم منفی همواره غالب خواهد بود. این ویژگی اثبات می‌کند که سیستم دارای پایداری ورودی-به-حالت (ISS) است. با این حال، در نزدیکی نقطه تعادل (مبدأ)، اثر اغتشاشات خطی قابل چشم‌پوشی نیست. بنابراین، خطا دقیقاً به صفر همگرا نمی‌شود، بلکه به یک مجموعه محدود باقی‌مانده وارد می‌شود. مرز این ناحیه یا شعاع همگرایی زمانی رخ می‌دهد که نرخ اتلاف انرژی با نرخ تولید انرژی توسط اغتشاش برابر شود ($\dot{H}_d = 0$).

بنابراین، شعاع خطای ماندگار (β) به صورت ریاضی طبق رابطه (۴۶) محاسبه می‌گردد:

$$\lambda_{min}(\mathfrak{R}_d) \|\tilde{Z}\|^2 = \delta \|\tilde{Z}\| \Rightarrow \|\tilde{Z}\| \leq \frac{\delta}{\lambda_{min}(\mathfrak{R}_d)} = \beta \quad (46)$$


که β شعاع همگرایی یا حداکثر خطای قابل انتظار، δ کران بالای عدم قطعیت‌های سیستم (تخمین بدترین حالت اغتشاشات بار و خازن) و $\lambda_{min}(\mathfrak{R}_d)$ کمترین مقدار ویژه ماتریس میرایی ($\mathfrak{R}_d$) است.

رابطه (۴۶) نشان می‌دهد که خطای ردیابی سیستم کران‌دار است. همچنین نشان می‌دهد، با افزایش مقادیر ماتریس میرایی ($\mathfrak{R}_d$) توسط طراح، مخرج کسر بزرگتر شده و شعاع خطا (β) کوچکتر می‌شود؛ بدین معنا که سیستم با دقت بیشتری در حضور عدم قطعیت‌ها به نقطه کار مطلوب نزدیک خواهد شد.

¹ Input-to-State Stability

به منظور اعتبارسنجی تحلیل های تئوری ارائه شده و بررسی رفتار دقیق سیستم در حضور عدم قطعیت های پارامتری (۲۰ درصد انحراف در مقادیر R و C)، رفتار مشتق زمانی تابع لیاپانوف ($\dot{H}_d$) به صورت عددی شبیه سازی و در شکل ترسیم شده است. همان طور که در شکل ۴-الف مشاهده می شود، تقابل میان ترم اتلافی (منحنی قرمز رنگ با رفتار درجه دوم) و ترم اغتشاش (خط چین سبز با رفتار خطی) به وضوح به تصویر کشیده شده است. اگرچه در مقادیر بسیار کوچک خطا، ترم اغتشاش غالب است، اما به محض عبور نرم خطا از مرز آستانه ($\beta = 0.4$)، ترم اتلافی با قدرت بر اغتشاشات غلبه کرده و موجب منفی شدن مشتق کل (خط آبی ضخیم) می گردد. این نقطه تلاقی، دقیقاً منطبق بر شعاع همگرایی محاسبه شده در روابط تئوری است.

علاوه بر این، شکل ۴-ب نمایش سه بعدی سطح انرژی سیستم را در فضای حالت خطای جریان و ولتاژ نشان می دهد. صفحه خاکستری نیمه شفاف، بیانگر مرز پایداری ($\dot{H}_d$) است. همان طور که پیداست، سطح انرژی تنها در یک ناحیه بسیار محدود حول مبدأ (قله مرکزی) از صفحه صفر فراتر رفته است (ناحیه خطای ماندگار) و در سایر نواحی فضای حالت، اکیداً زیر صفحه قرار دارد. این رفتار بصری، اثبات کننده خاصیت پایداری ورودی-به-حالت (ISS) سیستم پیشنهادی است، بدین معنا که متغیرهای حالت حتی در بدترین شرایط عدم قطعیت نیز هرگز واگرا نشده و همواره در یک همسایگی کوچک و کران دار باقی می مانند.



شکل ۴: ارزیابی عددی پایداری مقاوم سیستم در حضور عدم قطعیت ۲۰ درصدی پارامترها. (الف) رفتار دوبعدی اجزای مشتق لیاپانوف؛ نقطه تلاقی ترم های اتلافی و اغتشاش، شعاع همگرایی β را تعیین می کند. (ب) نمایش سه بعدی سطح $\dot{H}_d$ نسبت به صفحه پایداری (صفحه خاکستری)؛ ناحیه برآمده مرکزی نشان دهنده محدوده کوچک خطای ماندگار^۱ و سایر نواحی بیانگر پایداری مجانبی سیستم هستند.

۵- نتایج شبیه سازی و پیاده سازی عملی

۵-۱. چالش های موجود و رویکرد کنترلی پیشنهادی

اگرچه کنترل کننده های مبتنی بر انفعال (PBC) به دلیل تضمین پایداری مجانبی سیستم های غیرخطی از محبوبیت بالایی برخوردارند، اما عملکرد آن ها وابستگی شدیدی به دقت مدل ریاضی و پارامترهای سیستم (نظیر اندوکتانس و ظرفیت خازنی) دارد. در کاربردهای عملی، تغییرات اجتناب ناپذیر پارامترها و نوسانات ولتاژ ورودی، در روش PBC کلاسیک منجر به بروز خطای حالت ماندگار قابل توجهی می شود.

نوآوری محوری این پژوهش، ارائه یک ساختار کنترلی ترکیبی است که با ادغام پایداری ذاتی (روش PBC) و قابلیت ردیابی دقیق روش (PI آبخاری)، بر محدودیت های مذکور غلبه می کند. رویکرد پیشنهادی دارای سه جنبه نوآورانه کلیدی است:

^۱ Bounded Error Region

- تفکیک دینامیک پایدارسازی و ردیابی: در این ساختار، وظیفه شکل دهی انرژی و تضمین پایداری سیستم بر عهده حلقه داخلی (کنترل کننده PBC) است، در حالی که وظیفه تنظیم دقیق نقطه کار و حذف خطای حالت ماندگار به عهده حلقه خارجی (کنترل کننده PI) واگذار شده است. این هم افزایی باعث می شود که سیستم حتی در صورت تغییرات شدید پارامترها مقاومت و پایداری خود را حفظ کرده و به ولتاژ مطلوب همگرا شود.
- کنترل غیرمستقیم جریان محور: به منظور غلبه بر چالش غیرمینیم فاز بودن مبدل افزاینده، متغیر کنترلی اصلی در حلقه داخلی، جریان سلف انتخاب شده است که رفتاری مینیم فاز دارد. ولتاژ خروجی به صورت غیرمستقیم از طریق تنظیم پویای مرجع جریان (I_d^*) توسط حلقه بیرونی کنترل می شود. این تکنیک منجر به پاسخ گذرای بسیار سریع تر و حذف فراجش نسبت به روش های متداول گردیده است.
- **توزیع میرایی تطبیقی:** برخلاف روش های مرسوم که از ماتریس میرایی ثابت استفاده می کنند، در روش پیشنهادی، سیگنال کنترلی به صورت تطبیقی با شرایط لحظه ای بار و ولتاژ ورودی اصلاح می شود. نتایج عملی بیانگر بهبود چشمگیر قابلیت سیستم در دفع اغتشاشات لحظه ای است.

۵-۲. پیاده سازی سخت افزاری

به منظور اعتبارسنجی عملکرد رویکرد پیشنهادی و بررسی رفتار مبدل در شرایط واقعی، یک نمونه آزمایشگاهی از مبدل افزاینده طراحی و ساخته شده است. تصویر ۴ شماتیک کلی پیاده سازی سخت افزاری و حلقه کنترلی اعمال شده را نمایش می دهد و پارامترهای نامی سیستم در جدول ۲ ارائه شده اند. جزئیات سخت افزاری سیستم به شرح زیر تفکیک شده است:

الف) مدار قدرت: در بخش قدرت، از ماسفت IRFB4110 به عنوان سوئیچ اصلی قدرت استفاده شده است که توسط گیت درایور QP12W05S-37 راه اندازی می شود. همچنین جهت یکسوسازی خروجی، دیود شاتکی STP40H100CW مورد بهره برداری قرار گرفته است.

ب) پردازشگر مرکزی: برای پیاده سازی الگوریتم کنترلی به صورت دیجیتال، از میکروکنترلر STM32F103C8T6 مبتنی بر هسته ARM Cortex-M3 استفاده شده است. این پردازنده با سرعت پردازش مناسب، وظیفه خواندن مقادیر آنالوگ، اجرای محاسبات ریاضی کنترل کننده غیرخطی و تولید سیگنال PWM با چرخه کاری متغیر را بر عهده دارد.


ج) سیستم اندازه گیری و ملاحظات پیاده سازی دیجیتال: دقت و پایداری سیستم کنترل به شدت به کیفیت سیگنال های فیدبک وابسته است. بدین منظور، سیستم اندازه گیری و آماده سازی سیگنال با ملاحظات زیر طراحی شده است:

- اندازه گیری ایزوله: جهت اندازه گیری ولتاژ خروجی و حفظ ایزولاسیون الکتریکی بین مدار قدرت و بخش کنترل، از سنسور خطی اپتوکوپلر IL300 استفاده شده است. همچنین جریان سلف و جریان بار توسط سنسور اثر هال ACS712 اندازه گیری می شوند که ضمن داشتن پاسخ فرکانسی مناسب، ایزولاسیون لازم را فراهم می کند.
 - فیلترینگ سیگنال: با توجه به ماهیت سوئیچینگ مبدل و وجود نویزهای فرکانس بالا، سیگنال های خروجی سنسورها پیش از ورود به واحد مبدل آنالوگ به دیجیتال (ADC) میکروکنترلر، از یک فیلتر پایین گذر RC عبور داده می شوند تا اثرات نویز سوئیچینگ و پدیده الیزینگ^۱ کاهش یابد.
- علاوه بر فیلترهای سخت افزاری، به منظور جلوگیری از ناپایداری های ناشی از نویزهای اندازه گیری و دوشاخگی^۲ در الگوریتم کنترلی، تمهیدات نرم افزاری زیر در پردازنده دیجیتال لحاظ شده است:

¹ Aliasing

² Bifurcation

به منظور ارزیابی کارایی الگوریتم پیشنهادی در محیط واقعی، ساختار کنترلی طراحی شده ابتدا در قالب بلوک دیاگرام شکل ۵ مدل‌سازی گردید. در این ساختار، سیگنال‌های فیدبک ولتاژ و جریان پس از عبور از فیلترهای پایین‌گذر، وارد حلقه‌های کنترلی PI و سپس بلوک سازنده دینامیکی نسبت و وظیفه می‌شوند تا سیگنال PWM نهایی جهت درایو ماسفت تولید گردد. بر مبنای این طرح، نمونه آزمایشگاهی مبدل افزاینده مطابق شکل ۶ پیاده‌سازی شد. این بستر سخت‌افزاری شامل مدار قدرت، بردهای کنترلی مبتنی بر میکروکنترلر، و تجهیزات اندازه‌گیری دقیق است که امکان رصد بلادرنگ سیگنال‌ها و صحنه‌گذاری بر نتایج تئوری را فراهم می‌سازد.




شکل ۵: بلوک دیاگرام کنترل کننده پیشنهادی

جدول ۱: مشخصات نامی نمونه آزمایشگاهی پیاده‌سازی شده

واحد	مقدار	سمبل	پارامترها
<i>Volts</i>	۵۰	V_{ref}	ولتاژ مرجع
<i>Volts</i>	۳۱/۵	E	ولتاژ ورودی
<i>mH</i>	۱۰	L	اندوکتانس
μF	۱۰۰۰	C	خازن خروجی
$m\Omega$	۲۴	r_C	ESR ^۱ خازن
$m\Omega$	۱۰	r_L	ESR سلف
$m\Omega$	۳/۷	r_{DS}	مقاومت درین-سورس
$m\Omega$	۷	R_{ON}	R_{ON} دیود
<i>Volts</i>	۰/۵۷	V_F	V_F دیود
<i>KHz</i>	۲۰	f_{SW}	فرکانس سویچینگ

¹ Equivalent Series Resistance




شکل ۶: ساخت نمونه آزمایشگاهی مبدل بوست با کنترل کننده پیشنهادی

۳-۵. نتایج شبیه سازی و آزمایشگاهی

نتایج شبیه سازی و آزمایشگاهی مبدل افزاینده در حضور دو کنترل کننده CCLPI-PBC و PBC استخراج شده، که در ادامه مورد بحث و بررسی قرار می گیرد.


آزمایش ۱: در شکل ۷، نتایج شبیه سازی و آزمایشگاهی عملکرد مبدل افزاینده تحت فرمان دو کنترل کننده PBC و CCLPI-PBC مقایسه شده است. همان طور که در تصویر مشخص است، سناریوی آزمون شامل تغییر پله ای ولتاژ مرجع از ۵۵ ولت به ۴۲/۵ ولت می باشد.

با بررسی نمودارهای ولتاژ خروجی (شکل های الف و ب) و جریان سلف (شکل های ج و د)، مشاهده می شود که اگرچه هر دو روش کنترلی موفق به ردیابی مقدار مرجع و تثبیت ولتاژ شده اند، اما کنترل کننده پیشنهادی CCLPI-PBC رفتار دینامیکی برتری از خود نشان می دهد. این برتری به وضوح در زمان نشست کوتاه تر و سرعت همگرایی بالاتر نسبت به روش مرسوم PBC مشهود است که منجر به دستیابی سریع تر مبدل می گردد.




شکل ۷: نتایج آزمایشگاهی و شبیه سازی شکل موج های اصلی مبدل برای آزمایش ۱، الف) شبیه سازی ولتاژ خروجی، ب) نتیجه آزمایشگاهی ولتاژ خروجی، ج) نتیجه شبیه سازی جریان سلف، د) نتیجه آزمایشگاهی جریان سلف

آزمایش ۲: ارزیابی عملکرد در برابر تغییرات بار در این آزمایش، رفتار مبدل در مواجهه با تغییر پله‌ای بار (کاهش مقاومت خروجی از 25Ω به 19Ω) بررسی شده است. نتایج شبیه‌سازی و عملی این آزمایش در شکل‌های ۸ و ۹ نمایش داده شده‌اند. با تحلیل شکل ۸، مشاهده می‌شود که کنترل کننده CCLPI-PBC با موفقیت اغتشاش وارده را دفع کرده و ولتاژ خروجی را روی مقدار مرجع ۵۰ ولت تثبیت نموده است. این در حالی است که کنترل کننده کلاسیک PBC قادر به جبران کامل اثر بار نبوده و دچار خطای حالت ماندگار شده است (افت ولتاژ مشهود در شکل ۸-ب). همچنین شکل ۹، رفتار دینامیکی سیستم را در صفحه فاز (مسیر ولتاژ بر حسب جریان) ترسیم می‌کند. همان‌طور که در شکل ۹-الف پیداست، در روش PBC نقطه کار سیستم از نقطه آغازین A (۵۰ ولت) منحرف شده و در نقطه B (حدود ۴۷ ولت) ساکن می‌شود که نشان‌دهنده ناتوانی در تنظیم دقیق ولتاژ است. در مقابل، مسیر حالت در روش CCLPI-PBC (شکل ۹-ب) نشان می‌دهد که سیستم پس از یک گذار موقت، مجدداً به سطح ولتاژ مطلوب بازگشته و در نقطه B (همان ۵۰ ولت) همگرا شده است. این امر حاکی از مقاومت بالای روش پیشنهادی در برابر تغییرات بار است.




شکل ۸: نتایج شبیه‌سازی و آزمایشگاهی اجرای سناریو ۲، الف) نتیجه شبیه‌سازی ولتاژ خروجی، ب) نتیجه آزمایشگاهی ولتاژ خروجی، ج) نتیجه شبیه‌سازی جریان سلف، د) نتیجه آزمایشگاهی جریان سلف




شکل ۹: جهت ولتاژ خروجی بر اساس جریان سلف ناشی از اجرای سناریو ۲: الف) کنترل کننده PBC ب) کنترل کننده CCLPI+PIC.

آزمایش ۳: ارزیابی مقاومت در برابر تغییرات ولتاژ ورودی (Line Regulation) در این آزمایش، قابلیت اطمینان و پایداری سیستم در مواجهه با نوسانات منبع تغذیه بررسی شده است. بدین منظور، ولتاژ ورودی از ۳۲ ولت به ۲۴ ولت کاهش داده شده است، در حالی که ولتاژ مرجع خروجی روی ۵۰ ولت ثابت است. نتایج شبیه سازی و عملی این آزمایش در شکل های ۱۰ و ۱۱ منعکس شده است.

با تحلیل شکل ۱۰، ضعف عملکرد کنترل کننده PBC مشهود است؛ به طوری که با افت ولتاژ ورودی، این کنترل کننده قادر به حفظ رگولاسیون نبوده و ولتاژ خروجی آن به شدت افت کرده است. در مقابل، کنترل کننده پیشنهادی CCLPI-PBC رفتار بسیار مطلوب تری از خود نشان داده و پس از یک گذار کوتاه، موفق به دفع کامل اغتشاش و تثبیت مجدد ولتاژ روی ۵۰ ولت شده است. همچنین بررسی رفتار سیستم در صفحه فاز (شکل ۱۱) نشان می دهد که در روش PBC (شکل ۱۱-الف)، نقطه کار سیستم از نقطه مطلوب A (۵۰ ولت) خارج شده و به نقطه تعادل جدید و نامطلوب B (حدود ۲۷ ولت) جابجا شده است که بیانگر خطای فاحش سیستم است. اما در روش CCLPI-PBC (شکل ۱۱-ب)، مسیر حالت نشان می دهد که سیستم اگرچه ابتدا تحت تأثیر تغییر ورودی قرار گرفته، اما با یک دینامیک مطلوب مجدداً به نقطه تعادل اولیه B همگرا شده است. این نتایج به وضوح مقاومت بالای روش پیشنهادی را در برابر تغییرات شدید ولتاژ ورودی تایید می کند.



شکل ۱۰: مقایسه نتایج شبیه سازی و آزمایشگاهی اجرای سناریو ۳ برای ولتاژ ورودی و خروجی با بکارگیری دو کنترل کننده مورد بحث الف) شبیه سازی ب) نتایج عملی



شکل ۱۱: مسیر حرکت ولتاژ خروجی بر حسب جریان سلف در حالت تغییر ولتاژ ورودی از 32V به 24V

آزمایش ۴: در این آزمایش تحلیل حساسیت و بررسی مقاومت در برابر عدم قطعیت پارامترها مورد ارزیابی قرار می گیرد. در این بخش، عملکرد سیستم کنترلی در شرایطی که پارامترهای واقعی مدار با مقادیر نامی استفاده شده در طراحی کنترل کننده اختلاف دارند (عدم قطعیت پارامتری) ارزیابی می شود. بدین منظور، مقادیر ظرفیت خازنی (C) و مقاومت بار (R) به میزان $\pm 20\%$ نسبت به مقادیر نامی منحرف شده اند.


الف) تغییرات ظرفیت خازنی: با اعمال تغییر ۲۰ درصدی (کاهش و افزایش) در ظرفیت خازن خروجی نسبت به مقدار نامی ۱۰۰۰ میکروفاراد، نتایج آزمایشگاهی مطابق شکل ۱۲ حاصل شده است. همان طور که مشاهده می شود هر دو کنترل کننده در برابر نوسانات ظرفیت خازنی مقاوم بوده و ولتاژ خروجی را بدون انحراف حفظ کرده اند.

ب) تغییرات مقاومت بار: در این سناریو، مقدار نامی بار ۲۵ اهم در نظر گرفته شده است:


۱- افزایش مقاومت ($+20\%$): نتایج شکل ۱۳-الف نشان می دهد که با افزایش مقاومت، هر دو روش کنترلی عملکرد قابل قبولی داشته و ولتاژ را روی مقدار مرجع نگه داشته اند.

۲- کاهش مقاومت (-20%): چالش اصلی در شکل ۱۳-ب نمایان می شود؛ جایی که با کاهش مقاومت (افزایش بار)، ولتاژ خروجی در روش PBC دچار افت شده و نتوانسته از مقدار مرجع تبعیت نماید. اما کنترل کننده پیشنهادی CCLPI-PBC با حفظ دقیق ولتاژ خروجی، برتری خود را اثبات کرده است.

این آزمایش ها تایید می کنند که روش CCLPI-PBC نه تنها خاصیت تطبیقی دارد، بلکه در برابر عدم قطعیت های پارامتری (به ویژه در شرایط کاهش بار بحرانی) از مقاومت بسیار بالاتری نسبت به روش مرسوم برخوردار است.




شکل ۱۲: نتایج آزمایشگاهی ولتاژ خروجی با کاهش یا افزایش ۲۰ درصدی مقدار خازن خروجی.



شکل ۱۳: نتایج آزمایشگاهی: الف) ولتاژ خروجی با افزایش ۲۰ درصدی در مقدار مقاومت بار خروجی، ب) ولتاژ خروجی با کاهش ۲۰ درصدی در مقدار مقاومت بار خروجی.

آزمایش ۵: در این آزمایش تحلیل مقایسه‌ای عملکرد در برابر تغییرات پارامتر سلف در حضور دو کنترل کننده پیشنهادی و PBC مورد ارزیابی قرار می‌گیرد. پیش از این در مرجع [۲۰]، کنترل کننده‌های کلاسیک نظیر PI، PID، PR و PIR برای تنظیم ولتاژ مبدل DC-DC افزاینده مورد بررسی قرار گرفته‌اند؛ اما در این پژوهش تمرکز بر مقایسه دو روش غیرخطی PBC و CCLPI-PBC است. بدین منظور، رفتار مبدل در شرایطی که مقدار اندوکتانس سلف از ۱۰ میلی‌هانری به ۱ میلی‌هانری کاهش یافته (تغییر شدید پارامتر)، شبیه‌سازی شده است. نتایج حاصل در شکل ۱۴ نمایش داده شده و خلاصه عملکرد کمی دو روش در جدول ۲ ارائه گردیده است. شایان ذکر است که در محاسبه زمان نشست موجود در جدول، از معیار استاندارد باند خطای ۲٪ استفاده شده است.



شکل ۱۴: نتیجه شبیه سازی ولتاژ خروجی با تغییر مقدار سلف از ۱۰ میلی هانری به ۱ میلی هانری

همان طور که در نمودار شکل ۱۴ مشخص است، کنترل کننده PBC (منحنی آبی رنگ) در مواجهه با این تغییر پارامتر، دچار ضعف عملکرد شده و نمی تواند ولتاژ را روی مقدار مرجع ۵۰ ولت تثبیت کند؛ بطوری که با یک خطای حالت ماندگار قابل توجه، روی ولتاژی بالاتر (حدود ۵۲/۵ ولت) همگرا می شود. در مقابل، کنترل کننده پیشنهادی CCLPI-PBC (منحنی سبز رنگ)، علیرغم تغییر ۱۰ برابری پارامتر سلف، پس از یک زمان گذار بسیار کوتاه، با دقت کامل روی ولتاژ مرجع ۵۰ ولت منطبق می شود.

جدول ۲: مقایسه بین دو کنترل کننده

پارامتر	PBC	PBC+CCLPIC
زمان دامنه پیک (ثانیه)	0.0107	0.003284
زمان نشست (ثانیه)	0.08182	0.01801
خطا در حالت ماندگار (ولت)	2.55	0.01

بررسی داده های جدول ۲، برتری چشمگیر روش پیشنهادی را تایید می کند:


۱- سرعت پاسخ دهی: زمان نشست در روش پیشنهادی حدود ۰/۰۱۸ ثانیه است که تقریباً ۴/۵ برابر سریع تر از روش PBC (با ۰/۰۸۱ ثانیه) می باشد.

۲- دقت ردیابی: مهم ترین شاخصه خطای حالت ماندگار است. در حالی که روش PBC دارای خطای فاحش ۲/۵۵ ولت است، روش CCLPI-PBC این خطا را به مقدار ناچیز ۰/۰۱ ولت کاهش داده است.

بنابراین این نتایج به وضوح نشان می دهد که وابستگی روش PBC به پارامترهای دقیق مدل بسیار زیاد است، در حالی که ساختار تطبیقی CCLPI-PBC عملکرد سیستم را در برابر عدم قطعیت های شدید پارامتری کاملاً بیمه می کند.

حال اگر مقدار واقعی سلف از ۱۰ میلی هانری به ۱ میلی هانری کاهش یابد، ولتاژ مرجع تغییرات پله ای را تجربه کند. نتایج شبیه سازی ولتاژ خروجی و جریان سلف در شکل ۱۵ نمایش داده شده است. با دقت در شکل ۱۵-الف (نمودار ولتاژ)، مشاهده می شود که کنترل کننده PBC (منحنی آبی) به دلیل وابستگی شدید به پارامترهای مدل، در حضور این تغییر پارامتر دچار خطای فاحش شده و قادر به انطباق با ولتاژ مرجع (منحنی مشکی) نیست (ایجاد آفست ولتاژ). در مقابل، کنترل کننده پیشنهادی CCLPI-PBC (منحنی سبز) با مکانیزم تطبیقی خود، اثر تغییر کاهش ۱۰ برابری پارامتر سلف را خنثی کرده و با دقتی مطلوب، تغییرات ولتاژ

مرجع را در تمام سطوح دنبال نموده است. این آزمایش نشان دهنده برتری مطلق روش پیشنهادی در کاربردهای ردیابی ولتاژ تحت شرایط عدم قطعیت است. در جدول ۳ مقایسه‌ای بین این دو کنترل کننده انجام شده است.



شکل ۱۵: نتایج شبیه‌سازی سناریو ۵، الف) ولتاژ خازن، ب) جریان سلف

لذا با مقایسه کنترل کننده‌های PBC و PBC+CCLPIC با اعمال تغییرات در مقادیر سلف و ولتاژ مرجع می‌توان گفت که کنترل کننده PBC+CCLPIC بخوبی قادر به ردیابی ولتاژ مرجع بوده در حالی که کنترل کننده PBC ناموفق عمل کرده است. به منظور تبیین جایگاه و برتری روش پیشنهادی، یک مقایسه جامع میان استراتژی کنترلی توسعه یافته (CCLPI-PBC) و سایر روش‌های متداول کنترل مبدل‌های DC-DC در جدول ۳ ارائه شده است.

همان‌طور که در ادبیات موضوع بررسی شده است، کنترل کننده کلاسیک (PI/PID) علیرغم ساختار ساده، تنها قادر به تضمین پایداری محلی در اطراف نقطه کار خطی‌سازی شده است و اغلب در حضور نوسانات شدید بار و عدم قطعیت‌ها، عملکرد مطلوبی از خود نشان نمی‌دهد [۸، ۲۰]. در مقابل، روش‌های غیرخطی نظیر کنترل مد لغزشی (SMC) اگرچه پایداری سراسری و مقاومت بالایی در برابر اغتشاشات دارند، اما ذاتا دچار پدیده لرزش (Chattering) هستند که پیاده‌سازی عملی آن‌ها را دشوار می‌سازد [۹، ۱۲].

از سوی دیگر، کنترل کننده‌های مبتنی بر غیرفعال بودن (PBC) به دلیل تضمین پایداری مجانبی سراسری بر اساس تحلیل لیاپانوف، گزینه‌ای جذاب محسوب می‌شوند [۱۳، ۱۴]. با این حال، عیب عمده PBC کلاسیک، وابستگی شدید آن به مدل دقیق سیستم است، بطوریکه در صورت بروز عدم قطعیت در پارامترها، سیستم دچار خطای حالت ماندگار قابل توجهی می‌شود و برای رفع این نقیصه معمولاً نیاز به الگوریتم‌های تطبیقی پیچیده است [۱۶، ۱۷]. همچنین، روش‌های هوشمند نظیر شبکه‌های عصبی-فازی، اگرچه انعطاف‌پذیری بالایی دارند، اما اثبات پایداری آن‌ها دشوار بوده و بار محاسباتی سنگینی را به سیستم تحمیل می‌کنند [۴، ۷].

در این پژوهش، روش پیشنهادی (CCLPI-PBC) با تلفیق پایداری سراسری روش PBC و دقت بالای کنترل کننده انتگرالی، موفق شده است بدون پیچیدگی محاسباتی بالا، خطای حالت ماندگار را به طور کامل حذف نماید. همان طور که در جدول ۵ مشاهده می شود، این روش برخلاف رویکرد کلاسیک، پایداری سراسری را تضمین کرده و برخلاف PBC استاندارد، در برابر عدم قطعیت های پارامتری کاملاً مقاوم است. لازم بذکر است در این مقاله، مباحث پایداری ارائه شده تنها برای سیستم حلقه بسته با کنترل کننده PBC در قالب ساختار متمرکز معتبر است. مباحث نظری مربوط به پایداری سیستم کنترل با ساختار آبخاری می تواند به عنوان پیشنهاد برای ادامه کار مطرح گردد.

جدول ۳: مقایسه ای بین کنترل کننده پیشنهادی با دیگر کنترل کننده ها

روش کنترلی	خطای حالت ماندگار	مقاومت در برابر عدم قطعیت پارامتری	پاسخ دینامیکی (زمان نشست)	بار محاسباتی (پیچیدگی اجرا)	تضمین پایداری	چالش اصلی
روش پیشنهادی (CCLPI-PBC)	حذف شده (تقریباً صفر)	بسیار مقاوم	سریع	کم (معادلات جبری)	لیاپانوف	تنظیم ضرایب PI
کنترل مبتنی بر انفعال (PBC)	زیاد (قابل توجه)	حساس (وابسته به مدل)	کند	بسیار کم	سراسری	خطای ایستایی و وابستگی به مدل
کنترل کلاسیک (PI/PID)	حذف شده (به کندی)	ضعیف	متوسط/دارای فراجش	بسیار کم	محلی (حول نقطه کار)	کندی پاسخ و عدم پایداری سراسری
کنترل مد لغزشی (SMC)	کم	مقاوم	سریع	متوسط	سراسری	پدیده لرزش (Chattering)
کنترل پیش بین مدل (MPC)	حذف شده	وابسته به دقت مدل	سریع	بسیار زیاد (بهینه سازی آنلاین)	مشروط	حجم محاسبات سنگین و هزینه سخت افزار
روش های هوشمند (فازی)	کم	متوسط	متوسط	زیاد	دشوار در اثبات	عدم تضمین ریاضی پایداری

۶- نتیجه گیری

در این مقاله، یک ساختار کنترلی مقاوم و تطبیق پذیر برای تنظیم ولتاژ مبدل DC-DC افزاینده در حالت هدایت پیوسته (CCM) ارائه و پیاده سازی شد. چالش اصلی در کنترل این مبدل، ماهیت غیرمینیم فاز آن است که تنظیم مستقیم ولتاژ را دشوار می سازد. برای غلبه بر این چالش و همچنین رفع محدودیت های روش های مبتنی بر مدل، یک روش کنترلی ترکیبی با ادغام کنترل کننده مبتنی بر غیرفعال بودن (PBC) و کنترل کننده حلقه بسته آبخاری مبتنی بر PI (CCLPI) توسعه داده شد. در طرح پیشنهادی، ولتاژ خروجی به صورت غیرمستقیم و از طریق ردیابی دقیق جریان سلف کنترل می شود. تحلیل های ریاضی مبتنی بر تابع لیاپانوف اثبات نمود که قانون کنترلی استخراج شده، پایداری مجانبی سیستم حلقه بسته داخلی (مربوط به PBC) را تضمین می کند.

به منظور اعتبارسنجی عملکرد روش پیشنهادی، یک نمونه آزمایشگاهی با استفاده از پردازنده STM32 ساخته شد و در پنج آزمون سخت گیرانه شامل تغییرات پله ای ولتاژ مرجع، نوسانات ولتاژ ورودی، تغییرات بار و عدم قطعیت های پارامتری مورد ارزیابی قرار گرفت. نتایج مقایسه ای نشان داد که اگرچه کنترل کننده PBC کلاسیک پایداری کلی را حفظ می کند، اما در مواجهه با تغییرات ولتاژ ورودی و مقاومت بار، دچار خطای حالت ماندگار قابل توجهی می شود (به عنوان نمونه افت ولتاژ خروجی به ۲۷ ولت در اثر کاهش ورودی). در مقابل، کنترل کننده پیشنهادی (CCLPI-PBC) با بهره گیری از خاصیت انتگرالی حلقه بیرونی، ضمن حفظ پایداری، خطای حالت ماندگار را به طور کامل حذف کرده و ولتاژ خروجی را دقیقاً بر روی مقدار مرجع ۵۰ ولت تنظیم می نماید. علاوه بر این آزمون های مقاوم بودن نشان داد که روش پیشنهادی حساسیت بسیار کمی نسبت به تغییرات پارامترهای داخلی

مبدل دارد. نتایج عملی تایید کردند که حتی با اعمال عدم قطعیت ۲۰ درصدی در مقادیر ظرفیت خازنی و مقاومت بار، و همچنین تغییر شدید اندوکتانس سلف (از ۱۰ میلی‌هانری به ۱ میلی‌هانری)، سیستم عملکرد مطلوب و بدون نوسان خود را حفظ می‌کند. بنابراین، رویکرد پیشنهادی بدون تحمیل بار محاسباتی سنگین (برخلاف روش‌هایی نظیر MPC و بدون نیاز به شناسایی دقیق پارامترها)، راه‌حلی کارآمد، ساده و صنعتی برای کاربردهای حساس به نوسانات ولتاژ ارائه می‌دهد. همچنین تحلیل نظری دقیق پایداری سیستم آشناری با در نظر گرفتن اثرات متقابل دینامیک‌های کوپل شده بین دو حلقه کنترلی، می‌تواند به عنوان موضوعی برای پژوهش‌های آتی مورد بررسی قرار گیرد.

مراجع

1. Sedaghati, F. and S.A. Azimi. *A non-isolated bidirectional dc-dc converter connected to the t-type three level converter for electric vehicle battery charger*. in 2023 13th Smart Grid Conference (SGC). . IEEE.
2. Sofiya, S. and S. Sathyan, *A series inductance based three-port isolated hybrid DC-DC converter for microgrid applications*. Renewable Energy Focus, 2023. **47**: p. 100501.
3. Waghmare, T. and P. Chaturvedi, *A higher-order sliding mode controller's super twisting technique for a DC-DC converter in photovoltaic applications*. Energy Reports, 2023. **9**: p. 581-589.
4. Basha, C.H., et al., *Design of GWO based fuzzy MPPT controller for fuel cell fed EV application with high voltage gain DC-DC converter*. Materials Today: Proceedings, 2023. **92**: p. 66-72.
5. Kim, H.-S. and S.-U. Shin, *A High Conversion Ratio DC-DC Boost Converter with Continuous Output Current Using Dual-Current Flows*. Energies, 2023. **16**(8): p. 3603.
6. Jung, Y.-H., S.-K. Hong, and O.-K. Kwon, *A high-efficient and fast-transient buck-boost converter using adaptive direct path skipping and on-duty modulation*. Microelectronics journal, 2017. **70**: p. 43-51.
7. Wai, R.-J. and L.-C. Shih, *Adaptive fuzzy-neural-network design for voltage tracking control of a DC-DC boost converter*. IEEE transactions on power electronics, 2011. **27**(4): p. 2104-2115.
8. Jeong, G.J., I.H. Kim, and Y.I. Son, *Design of an adaptive output feedback controller for a DC/DC boost converter subject to load variation*. International Journal of Innovative Computing, Information and Control, 2011. **7**(2): p. 791-803.
9. Robles, J., F. Sotelo, and J. Chavez. *Robust nonsingular terminal sliding mode control with constant frequency for DC/DC boost converters*. in 2020 IEEE 21st Workshop on Control and Modeling for Power Electronics (COMPEL). 2020. IEEE.
10. Roy, T.K., et al. *Robust adaptive backstepping sliding mode controller for a DC-DC buck converter fed DC motor*. in 2021 Joint 10th International Conference on Informatics, Electronics & Vision (ICIEV) and 2021 5th International Conference on Imaging, Vision & Pattern Recognition (icIVPR). 2021. IEEE.
11. Salimi, M. and S. Siami. *Cascade nonlinear control of DC-DC buck/boost converter using exact feedback linearization*. in 2015 4th International Conference on Electric Power and Energy Conversion Systems (EPECS). 2015. IEEE.
12. Singh, S., N. Rathore, and D. Fulwani, *Mitigation of negative impedance instabilities in a DC/DC buck-boost converter with composite load*. Journal of Power Electronics, 2016. **16**(3): p. 1046-1055.
13. Sun, S., et al. *An Adaptive Passivity-Based Controller for Boost Converter Supplying Constant Power Load*. in IECON 2023-49th Annual Conference of the IEEE Industrial Electronics Society. 2023. IEEE.
14. Gupta, L. and S. Bhandari. *Modelling of Passivity based Controller for Buck Boost Converter*. in 2022 Second International Conference on Next Generation Intelligent Systems (ICNGIS). 2022. IEEE.
15. Rodriguez-Cortes, C.J., et al. *Passivity-based control for a high reduction ratio step-down converter in a battery charger application*. in 2024 International Symposium on Electromobility (ISEM). 2024. IEEE.
16. He, W., et al., *An adaptive passivity-based controller of a buck-boost converter with a constant power load*. Asian Journal of Control, 2019. **21**(1): p. 581-595.
17. Zaidi, A., A. Chaarabi, and N. Zanzouri. *Adaptive Passivity-based sliding mode control of a boost converter with parasitic parameters*. in 5th International Conference on Control Engineering & Information Technology (CEIT-2017) Proceeding of Engineering and Technology-PET. 2017.
18. Yazici, İ., *Robust voltage-mode controller for DC-DC boost converter*. IET Power Electronics, 2015. **8**(3): p. 342-349.
19. Ortega, R., et al., *Euler-Lagrange systems*, in *Passivity-based Control of Euler-Lagrange Systems: Mechanical, Electrical and Electromechanical Applications*. 1998, Springer. p. 15-37.
20. Padhmanabhaiyappan, S., R. Karthik, and K. Ayyar. *Investigation of controllers for dc-dc boost converter*. in 2018 International Conference on Power, Energy, Control and Transmission Systems (ICPECTS). 2018. IEEE.



Sahand University
of Technology

DOR:

[20.1001.1.23223146.1405.12.2.2.1](https://doi.org/10.1001.1.23223146.1405.12.2.2.1)

**Journal of Nonlinear
Systems in Electrical
Engineering**

Vol. 12, No. 2

Autumn and Winter 2025

ISSN: 2322 – 3146

<http://jnsee.sut.ac.ir>

Automated Multi-Parametric Analysis of Brain Lesions Over Time: A Detailed Deep Learning Framework for Quantitative Characterization

Mahdi Bashiri Bawil¹, Mousa Shamsi^{1,*}, Abolhassan Shakeri Babil²

¹ Department of Biomedical Engineering, Sahand University of Technology, Tabriz, Iran

² Department of Radiology, Tabriz University of Medical Sciences, Tabriz, Iran

*Corresponding author email: shamsi@sut.ac.ir

Abstract

Multiple sclerosis (MS) diagnosis relies on MRI lesion assessment, but qualitative approaches suffer from inter-observer variability, and advanced quantitative methods lack standardization, integrated longitudinal analysis capability, and clinical interpretability. This study aims to develop and validate a deep learning framework for automated multi-parametric quantitative characterization and longitudinal monitoring of MS lesions. T2-FLAIR data from 300 MS patients were analyzed using conditional generative adversarial networks (cGAN). The framework implements context-aware lesion refinement and neuroanatomically-informed classification to distinguish between periventricular, juxtacortical, and paraventricular hyperintensities. Multi-parametric analysis quantifies lesion features including count, area, and location, while the temporal analysis system enables automatic integration of multi-timepoint data and longitudinal change tracking. The framework achieved excellent correlation with expert assessments ($r = 0.975\text{--}0.989$, $\text{MAE} = 0.7\text{--}1.7$), and workflow efficiency improved with a 73.9% reduction in analysis time ($p < 0.01$). This framework bridges advanced image analysis, automated longitudinal monitoring, and clinical application, providing standardized metrics aligned with McDonald 2017 criteria for assessing disease progression over time.

Keywords

Multiple Sclerosis (MS), Deep Learning, MRI Lesion Characterization, Neuroanatomical Classification, Longitudinal Analysis

1. Short Introduction

Multiple sclerosis (MS) affects approximately 2.8 million people worldwide and involves heterogeneous pathological mechanisms leading to demyelination and neurodegeneration. MS diagnosis and monitoring rely heavily on MRI, yet qualitative radiological assessment suffers from significant inter- and intra-observer variability, especially for longitudinal monitoring. Automated deep learning approaches have advanced lesion segmentation, but systematic integration of multi-parametric characterization with longitudinal analysis and clinical interpretability in a single framework remains a challenge that the present work addresses.

2. Proposed Work

The framework processes T2-FLAIR MRI through preprocessing (noise reduction, brain extraction, intensity normalization), then dual cGAN models (pix2pix/U-Net architecture) produce initial segmentation masks. A context-aware lesion refinement algorithm resolves boundary ambiguities via spatial adjacency and geodesic distance analysis, followed by neuroanatomically-informed classification into periventricular, juxtacortical, and paraventricular categories. Five-domain quantification (count, area, penetration depth, hemispheric position, signal intensity) and an automated temporal analysis module enable longitudinal monitoring. Clinical validation with 3 neuroradiologists on 9 cases yielded $r = 0.975\text{--}0.989$ across all lesion categories, 73.9% reduction in analysis time ($p < 0.01$), and consensus expert rating of $9.0 \pm 0.0/10$ for clinical readiness.

3. Conclusion

The proposed end-to-end deep learning framework automates multi-parametric quantitative characterization and longitudinal monitoring of MS lesions, achieving correlation coefficients above 0.975 in all neuroanatomical categories while reducing analysis time by 73.9%. The framework provides standardized, reproducible metrics aligned with McDonald 2017 criteria with a readiness rating of 9.0/10 from expert neuroradiologists, with implications for precision medicine and clinical trial optimization.

تحلیل خودکار چندپارامتری ضایعات مغزی در گذر زمان: یک چارچوب کامل یادگیری عمیق برای مشخصه سازی کمی

مهدی بشیری باویل^۱، موسی شمسی^{۱*}، ابوالحسن شاکری باویل^۲



دانشگاه صنعتی سهند

DOR:

[20.1001.1.23223146.1405.12.2.2.1](https://doi.org/10.1001.1.23223146.1405.12.2.2.1)

^۱ دانشکده مهندسی پزشکی، دانشگاه صنعتی تبریز، تبریز، ایران

^۲ دانشکده رادیولوژی، دانشگاه علوم پزشکی تبریز، تبریز، ایران

* آدرس پست الکترونیکی نویسنده مسئول: shamsi@sut.ac.ir

نشریه سالانه علمی-پژوهشی «مندی برق»

دوره ۱۲ - شماره ۲

پاییز و زمستان ۱۴۰۴

صفحات ۲۹ الی ۴۶

ISSN: 2322-3146

<http://jnsee.sut.ac.ir>

تاریخ پذیرش: ۱۴۰۵/۳/۲۵

تاریخ بازنگری: ۱۴۰۴/۱۱/۲۸ و ۱۴۰۵/۳/۱۷

تاریخ ارسال: ۱۴۰۴/۸/۶

چکیده

واژه‌های کلیدی

مولتیپل اسکلروزیس

یادگیری عمیق

مشخصه یابی ضایعه با *MRI*

طبقه بندی نورواناتومیک

تحلیل طولی

تشخیص مولتیپل اسکلروزیس (MS) به ارزیابی ضایعات MRI متکی است، اما رویکردهای کیفی از تغییرپذیری بین ناظر رنج می‌برند و روش‌های کمی پیشرفته فاقد استانداردسازی، قابلیت تحلیل طولی یکپارچه و تفسیر بالینی هستند. هدف این مطالعه، توسعه و اعتبارسنجی یک چارچوب یادگیری عمیق برای مشخصه سازی کمی چندپارامتری خودکار و پایش طولی ضایعات MS است. داده‌های T2-FLAIR از ۳۰۰ بیمار MS با استفاده از شبکه‌های متخاصم مولد شرطی (cGAN) تحلیل شدند. این چارچوب، اصلاح ضایعات آگاه به زمینه و طبقه بندی نورواناتومیک را برای تمایز بین هایپر اینتنسیتیته‌های پری و نتریکولار، جاکستاکورتیکال و پاروانتریکولار پیاده سازی می‌کند. تحلیل چندپارامتری، ویژگی‌های ضایعه شامل تعداد، مساحت و موقعیت را کمی می‌کند و سیستم تحلیل گذر زمانی، یکپارچه سازی خودکار داده‌های چندزمانی و ردیابی تغییرات طولی را امکان پذیر می‌سازد. این چارچوب همبستگی عالی با ارزیابی‌های متخصصان به دست آورد ($r = 0.975 - 0.989$, $MAE = 0.7 - 1.7$) و کارایی گردش کار با کاهش ۷۳/۹٪ زمان تحلیل بهبود یافت ($p < 0.01$). این چارچوب، تحلیل پیشرفته تصویر، پایش طولی خودکار و کاربرد بالینی را پیوند می‌دهد و معیارهای استاندارد همسو با معیارهای مک دونالد ۲۰۱۷ را برای ارزیابی پیشرفت بیماری در گذر زمان ارائه می‌دهد.

۱. مقدمه

مولتیپل اسکلروزیس (MS) یک بیماری التهابی و تخریبی مزمن سیستم عصبی مرکزی است که تقریباً ۲/۸ میلیون نفر در سراسر جهان را تحت تأثیر قرار می‌دهد [۱]. این بیماری مکانیسم‌های پاتولوژیک ناهمگونی را نشان می‌دهد که منجر به دمیالیناسیون و نورودژنراسیون می‌شود [۲]. با چهار الگوی مشخص دمیالیناسیون که در افراد ثابت باقی می‌مانند در حالی که بین بیماران متفاوت هستند [۳]. این ناهمگونی که در سیر بالینی، تظاهرات نورورادیولوژیک و پاسخ درمانی منعکس می‌شود، چالش‌های قابل توجهی را برای تشخیص و برنامه‌ریزی درمان ایجاد می‌کند. رابطه مستقر بین ضایعات ماده سفید و آتروفی ماده خاکستری [۴] اهمیت مشخصه‌یابی جامع ضایعه از طریق تکنیک‌های پیشرفته تصویربرداری عصبی را برجسته می‌کند که سنگ بنای معیارهای تشخیصی فعلی را تشکیل می‌دهند و نیازمند شواهدی از پراکندگی ضایعات CNS در مکان و زمان هستند [۵].

تشخیص و پایش MS به شدت به MRI متکی است، با این حال چالش‌های متعددی در گردش کار رادیولوژیک باقی می‌ماند. ارزیابی کیفی توسط رادیولوژیست‌ها از تغییرپذیری قابل توجه بین‌ناظر و درون‌ناظر رنج می‌برد [۶،۷]، که به‌ویژه برای پایش طولی مشکل‌ساز است؛ جایی که تغییرات ظریف ممکن است در طی بررسی بالینی معمولی از دست بروند [۸]. این محدودیت در پایش طولی که نیازمند مقایسه سیستماتیک داده‌های چندزمانی برای ارزیابی پیشرفت بیماری و پاسخ درمانی است، بیشتر مشهود می‌شود. علی‌رغم دستورالعمل‌های اجماعی برای پروتکل‌های تصویربرداری MS، پیاده‌سازی به‌طور قابل توجهی در سراسر مؤسسات متفاوت است و موانعی را برای تحلیل کمی استاندارد ایجاد می‌کند و تعمیم‌پذیری روش‌های خودکار را محدود می‌کند [۹]. علاوه بر این، تمایز MS از بیماری‌های مشابه با پروتکل‌های متعارف چالش‌برانگیز باقی مانده است [۱۰]. نشانگرهای زیستی تصویربرداری پیشرفته، امید برای بهبود ویژگی را نشان می‌دهند اما با موانعی برای پذیرش بالینی گسترده به دلیل پروتکل‌های غیراستاندارد اکتسابی روبرو هستند [۱۱]. چالش‌های ادغام الگوریتم‌های هوش مصنوعی در گردش کارهای بالینی به‌طور سیستماتیک بررسی شده‌اند و هفت جزء نرم‌افزاری حیاتی لازم برای استقرار موفقیت‌آمیز شناسایی شده است [۱۲].

تحلیل ضایعات MS از ارزیابی کیفی پایه به رویکردهای محاسباتی پیشرفته تکامل یافته است و همچنین، نشان داده است که ویژگی‌های ضایعه فراتر از صرفاً حجم، حاوی اطلاعات تشخیصی و پیش‌آگهی ارزشمندی هستند [۱۳]. بخش‌بندی خودکار ضایعه پیشرفت‌های قابل توجهی را از طریق تکنیک‌های یادگیری عمیق دیده است، با مطالعاتی که دقت بالا را با استفاده از شبکه‌های عصبی کانولوشنال کاملاً متصل [۱۴] و رویکردهای طبقه‌بندی چندکلاسه [۱۵] نشان می‌دهند. رویکردهای گروهی عملکرد بخش‌بندی را بیشتر بهبود بخشیده‌اند [۱۶]، اگرچه استانداردسازی در پروتکل‌های تصویربرداری چالش‌برانگیز باقی می‌ماند. مرورهای سیستماتیک نشان می‌دهند که اکثر الگوریتم‌های یادگیری عمیق عملکرد کاهش‌یافته‌ای بر روی مجموعه داده‌های خارجی نشان می‌دهند [۱۷].

تحلیل الگوی فضایی به‌عنوان عامل حیاتی برای درک پاتوفیزیولوژی MS ظهور کرده است. محققان الگوهای فضایی مشخص هاپیرایننتسیت ماده سفید را از طریق تکنیک‌های خوشه‌بندی شناسایی کرده‌اند [۱۸] و توزیع فضایی ضایعه را که با پیشرفت ناتوانی همبستگی دارد کمی کرده‌اند [۱۹]. همچنین، سیستم‌های تقسیم‌بندی را که همبستگی‌های شناختی با الگوهای توزیع را آشکار می‌کنند [۲۰] توسعه داده‌اند. تحلیل طولی از روش‌های تفریق سنتی [۲۱] به رویکردهای محاسباتی پیشرفته‌ای، پیشرفت کرده است که عملکرد در سطح متخصص را به دست می‌آورند [۲۲-۲۴]، با سیستم‌های بالینی که اکنون برای هزاران بیمار مستقر شده‌اند [۲۵]. با این حال، یکپارچگی سیستماتیک تحلیل طولی با مشخصه‌سازی چندپارامتری جامع در یک چارچوب واحد، به‌ویژه با قابلیت ردیابی خودکار تغییرات در دسته‌بندی‌های نوروآناتومیک متعدد، هنوز چالشی باقی‌مانده است.

کار قبلی ما با معرفی طبقه‌بندی خودکار هاپیرایننتسیت‌های جاکستاکورتیکال [۲۶] و توسعه چارچوب‌هایی برای بخش‌بندی همزمان بطن و هاپیرایننتسیت‌های ماده سفید (WMH) در حالی که ضایعات نرمال را از پاتولوژیک تمایز می‌دهد [۲۷]، به این

چشم‌انداز کمک کرد. با این حال، رویکردهای موجود معمولاً بخش‌بندی و مشخصه‌یابی را به‌عنوان مسائل جداگانه بررسی می‌کنند و اغلب در ادغام تحلیل چندپارامتری با تفسیر بالینی ناکام می‌مانند.

این پژوهش چالش‌های حیاتی در تصویربرداری عصبی MS را از طریق یک چارچوب محاسباتی جامع بررسی می‌کند که ارزیابی‌های رادیولوژیک کیفی را به معیارهای کمی و تکرارپذیر تبدیل می‌کند. هدف اصلی ما ایجاد یک سامانه تحلیلی از ابتدا تا انتها برای مشخصه‌یابی قوی ضایعات MS با دقت تشخیصی بهبودیافته است. مشارکت‌های کلیدی شامل: (۱) یک چارچوب بخش‌بندی و طبقه‌بندی تخصصی که اصلاح ضایعات آگاه به زمینه را با طبقه‌بندی مبتنی بر اطلاعات نوروآناتومیک یکپارچه می‌کند؛ (۲) روش‌شناسی تحلیل چندپارامتری که پنج حوزه اصلی (تعداد، مساحت، عمق نفوذ، موقعیت نیمکره‌ای و شدت) را ارائه می‌کند؛ (۳) سیستم تحلیل گذر زمانی خودکار که یکپارچه‌سازی داده‌های چندزمانی و پایش طولی پیشرفت بیماری را امکان‌پذیر می‌سازد؛ (۴) چارچوب ارزیابی کمی استاندارد که ارزیابی‌های تکرارپذیر همسو با معیارهای تشخیصی تولید می‌کند؛ و (۵) اعتبارسنجی بالینی جامع که توافق بهبودیافته بین ناظر و دقت تشخیصی را نشان می‌دهد. این کار، تحقیق قبلی ما را برای ایجاد یک راه‌حل یکپارچه که تحلیل محاسباتی پیشرفته، پایش طولی خودکار و کاربرد بالینی عملی را پیوند می‌دهد، گسترش می‌دهد و بینش‌های قابل اقدامی را برای ارزیابی پیشرفت بیماری و تصمیم‌گیری درمانی فراهم می‌کند؛ در حالی که استانداردهای جدیدی را برای مشخصه‌سازی کمی ضایعات MS در گذر زمان ایجاد می‌کند.

۲. مواد و روش‌ها

۲/۱. جمعیت بیماران و اکتساب داده

این مطالعه گذشته‌نگر، داده‌های تصویربرداری T2-FLAIR از ۳۰۰ بیمار MS (۷۹ مرد، ۲۲۱ زن؛ محدوده سنی: ۱۸-۶۸ سال) را که طبق معیارهای مک‌دونالد ۲۰۱۷ [۲۸] در مرکز تصویربرداری پزشکی گلگشت تبریز تشخیص داده شدند، تحلیل کرد. تأیید اخلاقی از کمیته اخلاق تحقیقات دانشگاه علوم پزشکی تبریز (IR.TBZMED.REC.1402.902) اخذ شد. تمام معاینات MRI با استفاده از اسکنر TOSHIBA Vantage با قدرت ۱/۵ تسلا با پروتکل‌های استاندارد T2-FLAIR ($0.9 \times 0.9 \times 6.0 \text{ mm}^3$) انجام شد. $TI=2,500\text{ms}$ ، $TE=100\text{ms}$ ، $TR=10,000\text{ms}$ ، ابعاد و کسل: $0.9 \times 0.9 \times 6.0 \text{ mm}^3$ انجام شد.

داده‌های مرجع بخش‌بندی از طریق بخش‌بندی دستی جامع توسط یک نورورادیولوژیست استاد تمام دانشگاه با بیش از ۲۰ سال تخصص در تصویربرداری MS، با استفاده از یک رابط کاربری گرافیکی سفارشی مبتنی بر پایتون، ایجاد شد. سه کلاس آناتومیک تعریف شدند: سیستم بطنی، WMH غیرنرمال نشان‌دهنده کاندیدهای ضایعه MS و WMH نرمال از اثرات آلودگی مایع مغزی نخاعی (CSF) پری‌ونتری‌کولار. روش‌شناسی بخش‌بندی تفصیلی و رویه‌های اعتبارسنجی قبلاً توضیح داده شده است [۲۶، ۲۷].

۲/۲. معماری چارچوب محاسباتی

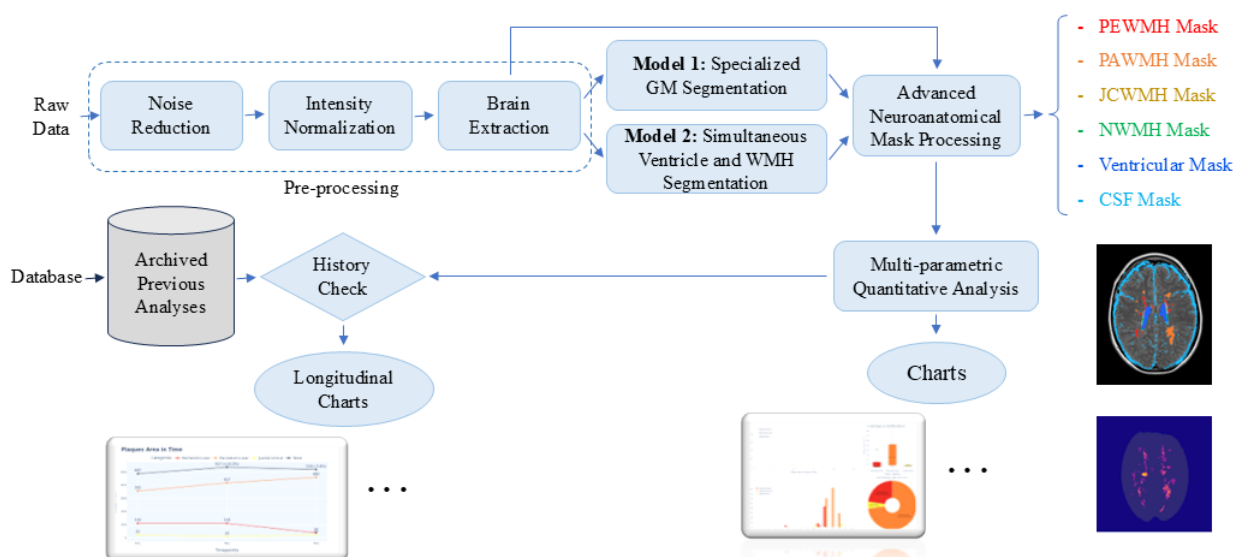
۲/۲/۱. پیش‌پردازش تصاویر و مدل‌های یادگیری عمیق

همان‌طور که در شکل (۱) نشان داده شده است، سیر پیش‌پردازش داده‌های خام تصویربرداری FLAIR از طریق سه مرحله متوالی انجام می‌گیرد: حذف نویز از طریق فیلتر میانه (اندازه هسته 3×3) و به دنبال آن فیلترینگ انتخابی گاوسی ($\sigma = 1.0$)، استخراج مغز مبتنی بر مورفولوژی با استفاده از تقریب ماسک بیضوی، و نرمال‌سازی شدت روشنایی اسلایس محور به محدوده [۰، ۱]. از خروجی این مراحل جهت استخراج ماسک CSF با استفاده از آستانه‌گذاری اوتسو و تغذیه مدل‌های بخش‌بندی استفاده می‌شود. دو شبکه متخاصم مولد شرطی (cGAN) تخصصی با استفاده از معماری pix2pix ماسک‌های پایه را تولید می‌کنند: (۱) بخش‌بندی تخصصی ماده خاکستری از تصاویر FLAIR [۲۶] و (۲) بخش‌بندی همزمان چندکلاسه که ماسک‌های بطنی، WMH نرمال و

WMH غیرنرمال را تولید می‌کند [۲۷]. هر دو مدل از مولدهای U-Net با هشت بلوک نمونه‌برداری کاهشی و هفت بلوک نمونه‌برداری افزایشی استفاده می‌کنند و با استفاده از توابع هزینه ترکیبی متخاصم و L1 آموزش داده شده‌اند. پروتکل آموزش مدل‌های بخش‌بندی، که در مطالعات پیشین نویسندگان [۲۶، ۲۷] به تفصیل شرح داده شده، به اختصار به شرح زیر است؛ داده‌ها با تقسیم‌بندی طبقه‌بندی شده در سطح بیمار به نسبت ۲۰/۱۰/۷۰ درصد (آموزش/اعتبارسنجی/آزمون) تفکیک شدند تا از نشت داده میان زیرمجموعه‌ها جلوگیری گردد. آموزش با ۶۰ دوره (با معیار توقف زودهنگام بر اساس صبر ۱۰ دوره) و اندازه دسته ۸ انجام پذیرفت. بهینه‌ساز Adam با نرخ یادگیری اولیه ۰/۰۰۰۲ و زمان‌بندی کاهش تطبیقی (فاکتور کاهش = ۰/۵، صبر = ۵ دوره) به کار گرفته شد. فرآیند آموزش به صورت دو مرحله‌ای طراحی شد: ۲۰ دوره اولیه با تابع هزینه آنتروپی متقاطع وزن‌دار برای همگرایی اولیه، و ادامه آموزش با تابع هزینه کانونی یکپارچه برای بهبود عملکرد در کلاس‌های کم‌نمونه. مدیریت عدم توازن کلاس‌ها از طریق ترکیب تابع هزینه کانونی، لایه‌های dropout و نرمال‌سازی دسته‌ای تأمین شد. در فرآیند آموزش از هیچ‌گونه داده‌افزایی استفاده نشده است.

۲/۲/۲. پردازش پیشرفته ماسک‌ها و طبقه‌بندی نورواناتومیک

پنج ماسک اولیه تحت پس‌پردازش پیشرفته قرار می‌گیرند تا شش ماسک نهایی مرتبط تولید شود. یک نوآوری حیاتی در رویکرد ما شامل اصلاح زمینه‌ای طبقه‌بندی هائیرایننتسیتیه بین WMH‌های نرمال و غیرنرمال است. الگوریتم اصلاح ضایعات آگاه به زمینه ما ابهام ذاتی در بخش‌بندی خودکار را با پیاده‌سازی تحلیل مجاورت که WMH‌های نرمال مجاور فضایی با WMH‌های غیرنرمال را در یک آستانه شعاع ۱ میلی‌متری شناسایی می‌کند، بررسی می‌کند. با تشخیص اینکه ضایعات MS از نظر پاتولوژیک از دیواره‌های بطنی منشأ می‌گیرند و به صورت عمود بر ماده سفید مجاور گسترش می‌یابند، این الگوریتم نواحی مجاور با مرزهای بطنی را ادغام می‌کند و متعاقباً نواحی هائیرایننتس مجاور را که نشان‌دهنده موجودیت‌های پاتولوژیک منفرد هستند، ادغام می‌کند. این فرآیند اصلاح زمینه‌ای اطمینان می‌دهد که ماسک‌های WMH نرمال و غیرنرمال حاصل، پاتوفیزیولوژی زیربنایی را به‌طور دقیق‌تری منعکس می‌کنند.



شکل (۱): نمای کلی چارچوب یادگیری عمیق پیشنهادی از ابتدا تا انتها برای تحلیل جامع ضایعات MS. فرآیند شامل پیش‌پردازش پشته‌های تصاویر خام FLAIR، مدل‌های بخش‌بندی دوگانه، پردازش پیشرفته ماسک‌ها، و تحلیل‌های کیفی و کمی برای تولید نتایج جامع و گزارش‌های بالینی می‌باشد. در نهایت، پایگاه داده را برای نقاط زمانی قبلی موجود یک بیمار مشخص، جهت انجام تحلیل‌های طولی بررسی می‌کند.

ماسک WMH غیرنرمال اصلاح شده تحت طبقه‌بندی مبتنی بر اطلاعات نوروآناتومیک به سه زیرمجموعه بالینی مهم طبق معیارهای استاندارد توپوگرافی ضایعات MS قرار می‌گیرد. WMH های پری و نتریکولار به عنوان ضایعات هایپراینتنس واقع در فاصله ژئودزیک ۳-۱۰ میلی متری از مرزهای بطنی تعریف می‌شوند، با معیارهای اضافی که نیازمند کوتاه‌ترین فاصله کمتر از ۵ میلی متر یا فاصله مرکز جرم کمتر از ۱۰ میلی متر هستند. WMH های جاکستاکورتیکال، با استفاده از بخش‌بندی تخصصی ماده خاکستری کورتیکال برای ترسیم دقیق مرز، بر اساس نزدیکی به اتصال ماده خاکستری-سفید (کوتاه‌ترین فاصله کمتر از ۳ میلی متر) و محدودیت‌های اندازه (مساحت مقطع عرضی کمتر از ۲۰ میلی متر مربع) طبقه‌بندی می‌شوند. WMH های عمیق ماده سفید (پاراوونتریکولار) شامل WMH های پاتولوژیک باقی مانده‌ای هستند که معیارهای پری و نتریکولار یا جاکستاکورتیکال را برآورده نمی‌کنند. این رویکرد مبتنی بر اطلاعات نوروآناتومیک، پنج ماسک اولیه را به شش طبقه‌بندی نهایی مرتبط با بالین تبدیل می‌کند: ماسک WMH پری و نتریکولار، ماسک WMH پاراوونتریکولار، ماسک WMH جاکستاکورتیکال، ماسک نهایی WMH نرمال، ماسک بطنی و ماسک CSF.

۲/۳. تحلیل کمی چند پارامتری

۲/۳/۱. چارچوب استخراج ویژگی

تحلیل کمی ما به طور سیستماتیک نشانگرهای زیستی تصویربرداری را از طریق ارزیابی چندپارامتری در پنج حوزه اصلی استخراج می‌کند. (۱) تعداد ضایعه: شناسایی ضایعه گسسته از طریق تحلیل مؤلفه‌های متصل با استفاده از اتصال-هشت برای تحلیل دوبعدی، محاسبه کل ضایعات در هر تصویر و تجمیع تعداد در حجم‌های بیمار. (۲) کمی سازی مساحت: اندازه گیری‌های مبتنی بر پیکسل تبدیل شده به واحدهای مساحت فیزیکی با استفاده از پارامترهای وضوح فضایی مکنتسب از هدرهای DICOM، با تقریب حجمی که از یکپارچگی ضخامت برش استفاده می‌کند و تخمین‌هایی از حجم کل بطنی و CSF ارائه می‌دهد [۲۹،۳۰]. (۳) عمق نفوذ: محاسبات حداقل فاصله اقلیدسی از هر مرکز جرم ضایعه تا نزدیک‌ترین مرز CSF یا بطنی، که بینش‌هایی در مورد مکانیسم‌های پاتوفیزیولوژیک شکل‌گیری ضایعه در اطراف وریدها و نول‌های پری و نتریکولار، مشخصه پاتولوژی MS، ارائه می‌دهد [۲۸]. (۴) موقعیت نیمکره‌ای: تعیین از طریق حداقل فاصله از مرکز جرم ضایعه تا بیرونی‌ترین خطوط کانتور نیمکره مغزی، با الگوهای توزیع فضایی که ارزش تشخیصی و پیش‌آگهی قابل توجهی برای تمایز MS از سایر بیماری‌های ماده سفید ارائه می‌دهند [۳۱]. (۵) مشخصه‌یابی شدت: مقادیر شدت میانه محاسبه شده برای پیکسل‌های درون هر ضایعه با استفاده از تصاویر FLAIR نرمال‌سازی شده، که اطلاعاتی در مورد ناهمگونی ضایعه و زیرگروه‌های پاتولوژیک احتمالی مربوط به مراحل مختلف دمی‌لیناسیون و التهاب ارائه می‌دهند [۱۰].

۲/۳/۲. روش‌های تحلیل آماری

چارچوب آماری ما تحلیل چندسطحی را به کار می‌گیرد که ویژگی‌های ضایعه را در سطح ضایعات فردی، برش‌های آناتومیک و ارزیابی‌های کلی بیمار مشخص می‌کند. (۱) تحلیل ضایعه محور مشخصه‌یابی تفصیلی موجودیت‌های پاتولوژیک گسسته را با مقادیر ویژگی که به طور سیستماتیک در ترتیب صعودی سازمان‌دهی شده‌اند، برای تسهیل شناسایی الگوی توزیع ارائه می‌دهد. (۲) تحلیل برش محور، با محاسبه مقادیر تجمعی با میانگین‌گیری وزن‌دار بر اساس مساحت ضایعه برای سایر ویژگی‌ها بجز اندازه گیری‌های تعداد و مساحت، بینش فضایی را از طریق تجمیع در سطح برش آناتومیک ارائه می‌دهد. (۳) ارزیابی کلی بیمار معیارهای جامع بار بیماری را از طریق تجمیع سیستماتیک همه اندازه‌گیری‌های ضایعه تولید می‌کند. این امر با پیاده‌سازی میانگین‌گیری وزن‌دار بر اساس مساحت برای عمق نفوذ، موقعیت نیمکره‌ای و شدت روشنایی همراه است تا اطمینان حاصل شود که ضایعات بزرگ‌تر به طور مناسب بر اندازه‌گیری‌های کلی تأثیر می‌گذارند. تجسم آماری پیشرفته از نمودارهای جعبه‌ای استفاده می‌کند که توزیع پارامتر را در سه

زیرمجموعه WMH غیرنرمال، با محاسبه آمار توصیفی شامل میانگین، انحراف معیار، میانه و دامنه برای تفسیر بالینی و کاربردهای تحقیقاتی، مشخص می‌کند.

۲/۴. تحلیل گذر زمانی

یکی دیگر از قابلیت‌های کلیدی چارچوب پیشنهادی ما، امکان تحلیل طولی خودکار از طریق یکپارچه‌سازی داده‌های تصویربرداری چندزمانی است. این ویژگی به‌طور خاص برای پایش پیشرفت بیماری MS و ارزیابی پاسخ درمانی در گذر زمان طراحی شده است.

سیستم ما یک معماری آرشیو ساختاریافته را برای ذخیره‌سازی نتایج تحلیل هر بیمار پیاده‌سازی می‌کند. هنگامی که داده‌های تصویربرداری جدیدی برای یک بیمار وارد سیستم می‌شود، چارچوب به‌طور خودکار با استفاده از شناسه یکتای بیمار (کد ملی)، آرشیو را برای تحلیل‌های قبلی جستجو می‌کند. اگر یک یا چند نقطه زمانی (timepoint) قبلی برای بیمار در پایگاه داده موجود باشد، سیستم تمام اطلاعات تاریخی شامل ماسک‌های بخش‌بندی شده، معیارهای کمی، و متادیتای تصویربرداری را بازیابی می‌کند. تحلیل گذر زمانی بر اساس مقایسه سیستماتیک تمام پارامترهای کمی استخراج شده در بخش ۲.۳ بین نقاط زمانی متوالی انجام می‌شود. برای هر یک از شش ماسک در دسته‌بندی‌های نوروآناتومیک، تغییرات پارامترها به دو صورت به نمودار کشیده می‌شود. (۱) تغییرات مطلق: اختلاف عددی مستقیم بین مقادیر فعلی و قبلی برای تمام پارامترهای کمی (تعداد ضایعه، مساحت/حجم کل، میانگین عمق نفوذ، توزیع نیمکره‌ای و شدت روشنایی) و (۲) تغییرات نسبی: محاسبه درصد تغییر نسبت به نقطه زمان قبل برای هر پارامتر.

نتایج تحلیل گذر زمانی از طریق نمودارهای خطی زمانی با نمایش روند تغییرات هر پارامتر در طول زمان جهت چندین تفسیر بالینی ارائه می‌شوند. این ویژگی تحلیل گذر زمانی، بینش جامع و مفیدی از وضعیت تکاملی ضایعات مغزی و سایر شاخص‌های نوروآناتومیک برای متخصصان فراهم می‌کند و به تصمیم‌گیری بالینی آگاهانه در مدیریت بیماران MS کمک می‌کند.

۲/۵. پروتکل اعتبارسنجی بالینی

۲/۵/۱. طراحی ارزیابی متخصصان

ما اعتبارسنجی بالینی جامعی را با مشارکت سه نورورادیولوژیست متخصص، اساتید دانشگاه، که دارای سطوح مختلف تجربه بودند، ۲۰+ سال، ۸-۱۲ سال و ۲-۵ سال، انجام دادیم. جهت ارزیابی یک مجموعه از تعداد نه بیمار MS بر اساس میزان بار ضایعات انتخاب شد: سه مورد با بار ضایعه کم (≤ 10)، سه مورد با بار ضایعه متوسط ($10-30$) و سه مورد با بار ضایعه بالا (≥ 30)، شامل ویژگی‌های جمعیتی متنوع (سن ۲۶-۵۹ سال، توزیع جنسیتی متعادل) و موارد چالش‌برانگیز با الگوهای غیرمعمول. همه داده‌ها تحت ناشناس‌سازی با شناسه‌های مطالعه (MS-001 تا MS-009) قرار گرفتند.

۲/۵/۲. پروتکل ارزیابی و معیارها

ارزیابی از یک پروتکل سه مرحله‌ای پیروی کرد. مرحله ۱ شامل تحلیل سنتی تنها با استفاده از تصاویر FLAIR بود. پس از یک وقفه یک‌هفته‌ای، مرحله ۲ همان موارد را با خروجی‌های خودکار کامل ارائه کرد. مرحله ۳ شامل پرسشنامه‌های ارزیابی مقایسه‌ای بود. موارد تحت ارزیابی برای جلوگیری از سوگیری‌های ذهنی، تصادفی‌سازی شدند و متخصصان به‌طور مستقل کار کردند. اعتبارسنجی کمی شامل اندازه‌گیری‌های کارایی زمانی، ارزیابی‌های دقت با استفاده از مقیاس‌های لیکرت ۵ نقطه‌ای، اعتبارسنجی تعداد ضایعات با تحلیل همبستگی، و ارزیابی اطمینان تشخیصی بود. تحلیل آماری از آزمون‌های t زوجی برای مقایسه

زمان و ضرایب همبستگی برای ارزیابی دقت، با معیارهای موفقیت از پیش تعریف شده شامل دقت تشخیصی ≥ 0.85 ، توافق و نمرات سودمندی بالینی $\geq 4.5/5$ ، استفاده کرد.

۲/۶. تجسم و پیاده سازی

تکنیک‌های تجسم جامع، داده‌های پیچیده بخش‌بندی را از طریق تجسم همپوشانی رنگی کد شده با ماسک‌های نیمه‌شفاف با استفاده از طرح‌های رنگی بهینه‌سازی شده بالینی، تحلیل نقشه حرارتی دوبعدی برای ارزیابی توزیع ضایعات، و نمودارهای کمی جامع با مشخصه‌یابی آماری از طریق نمودارهای جعبه‌ای و تجسم‌های تحلیل نسبی به اطلاعات قابل تفسیر بالینی تبدیل می‌کنند. همه اجزا برای یکپارچگی گردش کار بالینی و سیستم‌های پشتیبانی تصمیم طراحی شده‌اند.

این چارچوب با استفاده از Python 3.9 با TensorFlow بر روی یک ایستگاه کاری مجهز به پردازنده Intel Core i7-7700K، ۳۲ گیگابایت RAM و GPU NVIDIA RTX 3060 پیاده‌سازی شد. تحلیل کامل از ابتدا تا انتها، داده‌های T2-FLAIR با فرمت DICOM را در $11/2 \pm 22/4$ ثانیه در هر مورد پردازش می‌کند. تغییرات زمان پردازش با بار ضایعات همبستگی دارد. جزئیات زمان پردازش بدین گونه است: پیش‌پردازش (۲/۴ ثانیه)، بخش‌بندی یادگیری عمیق (۴ ثانیه)، پردازش ماسک (≥ 2 ثانیه)، تحلیل چندپارامتری ($13/1 \pm 9$ ثانیه)، و تحلیل گذر زمانی (≥ 1 ثانیه) که نیاز محاسباتی اولیه را به دلیل مشخصه‌یابی کمی جامع در پنج حوزه تحلیلی نشان می‌دهد.

۳. نتایج

۳/۱. عملکرد چارچوب و تجسم


چارچوب تحلیل چندپارامتری به‌طور موفقیت‌آمیزی تجسم‌های قابل تفسیر بالینی و ارزیابی‌های کمی جامع را در همه ۳۰۰ بیمار MS تولید کرد. شکل (۲) ظرفیت چارچوب برای تبدیل داده‌های پیچیده بخش‌بندی به همپوشانی‌های رنگی کد شده استاندارد را نشان می‌دهد که ارزیابی سریع توزیع بار ضایعه را در برش‌های محوری FLAIR امکان‌پذیر می‌سازد. الگوریتم طبقه‌بندی مبتنی بر اطلاعات نوروآناتومیک به‌طور مؤثر بین ضایعات پری‌ونتریکولار، جاکستاکورتیکال و پاراونتریکولار طبق معیارهای تشخیصی مستقر MS تمایز قائل شد، با تفکیک فضایی واضح که پایداری به دستورالعمل‌های مک‌دونالد ۲۰۱۷ را تأیید می‌کند.

شکل (۳) توزیع مقایسه‌ای ضایعات را از طریق تجسم دوگانه نقشه حرارتی نشان می‌دهد که الگوهای مخصوص بیمار همسو با ترجیحات توپوگرافیک مستقر MS را آشکار می‌کند؛ در حالی که استانداردهای مرجع سطح جمعیت را برای شناسایی ویژگی‌های توزیع غیرمعمول فراهم می‌کند. تحلیل این بیمار نمونه، مشخصه خوشه‌بندهای پری‌ونتریکولار را با شدت بیشتر در بخش فرونتال مغز نشان داد، در حالی که تجمع داده‌های جمعیت، نقاط داغ مورد انتظار را در نواحی پری‌ونتریکولار تأیید کرد.


۳/۲. تحلیل کمی چندپارامتری

۳/۲/۱. مشخصه سازی جامع ضایعه


چارچوب خودکار به‌طور موفقیت‌آمیزی نشانگرهای زیستی کمی را در پنج حوزه اصلی برای همه دسته‌های ضایعه استخراج کرد. شکل (۴) تحلیل نمایانگر تعداد ضایعه را نشان می‌دهد که الگوهای توزیع ناهمگون را با ضایعات پری و پاراونتریکولار که به‌طور مداوم در نواحی مرکزی مغز (برش‌های ۶-۱۴) غالب هستند، آشکار می‌کند، که با توزیع آناتومیک در اطراف بطن‌های جانبی، مشخصه پاتولوژی MS، مطابقت دارد. این ضایعات الگوهای توزیع متغیری را با تعداد اوج در نواحی مغزی میانی نشان دادند، در حالی که ضایعات جاکستاکورتیکال حضور ثابت اما پایین‌تری را در سراسر نواحی رابط کورتیکال نشان دادند.



شکل (۲): تجسم چندحالتی برش‌های محوری نمایانگر FLAIR از بیمار مبتلا به مولتیپل اسکلروزیس. برش‌های پیش‌پردازش‌شده اصلی به‌طور متناوب با همپوشانی‌های ماسک رنگی کد شده با استفاده از طرح استاندارد نشان داده می‌شوند: قرمز (پری‌ونتری‌کولار)، نارنجی (پاراونتری‌کولار)، زرد (جاکستاکورتیکال)، سبز (هایپراینتنسیته‌های نرمال)، آبی تیره (بطن‌ها)، و آبی آسمانی (مایع مغزی نخاعی).




شکل (۳): نقشه‌های حرارتی توزیع ضایعات را برای (چپ) بیمار نمونه و (راست) مرجع جمعی ($n=300$) نشان می‌دهند.




شکل (۴): تحلیل تعداد ضایعات (الف) تعداد ضایعات برش محور بر اساس دسته: پری و نتریکولار (قرمز)، پاراونتریکولار (نارنجی)، جاکستاکورتیکال (زرد). (ب) بار ضایعه نسبی بر اساس دسته.

شکل (۵) تحلیل جامع مساحت را ارائه می‌دهد که ناهمگونی مورفومتریک قابل توجه را در دسته‌های ضایعه آشکار می‌کند. ضایعات پری و نتریکولار و پاراونتریکولار محدوده‌های توزیع اندازه گسترده‌ای را نشان دادند، در حالی که ضایعات جاکستاکورتیکال توزیع‌های کوچک‌تر اما یکنواخت را که محدودیت‌های آناتومیک در رابط ماده خاکستری-سفید را منعکس می‌کنند، نشان دادند. مشخصه‌یابی آماری از طریق تحلیل نمودار جعبه‌ای نشان داد که ضایعات پاراونتریکولار بالاترین میانگین مساحت را نشان می‌دهند، با الگوهای تغییرپذیری قابل توجه بین دسته‌ای که معیارهای شدت بیماری مرتبط با بالین را فراهم می‌کنند. شکل (۶) محفظه‌های مایع مغزی نخاعی را نشان می‌دهد. مساحت بطنی الگوهای توزیع آناتومیک مشخصه‌ای را با مقادیر اوج در نواحی مرکزی مطابق با بدنه بطن‌های جانبی نشان می‌دهد. مشابه شکل (۶)، تحلیل‌های تکمیلی هاپرانتنسیت‌های نرمال ماده سفید و مایع مغزی نخاعی را نیز می‌توان ارائه نمود که جهت ارزیابی روند پیری مغز، آتروفی مغزی، توزیع‌های فضاهای کورتیکال و عمیق اطلاعات مفیدی فراهم می‌کند.



شکل (۵): تحلیل مساحت ضایعات. (الف) مساحت ضایعات فردی بر اساس دسته: پری و نتریکولار (قرمز)، پاراونتریکولار (نارنجی)، جاکستاکورتیکال (زرد). (ب) توزیع آماری بر اساس دسته. (ج) توزیع مساحت برش محور. (د) سهم نسبی مساحت بر اساس نوع ضایعه.





شکل (۶): تحلیل مساحت بطنی با توزیع مساحت بر اساس برش.

۳/۲/۲. مشخصه سازی فضایی و شدت

شکل (۷) تحلیل عمق نفوذ را ارائه می‌دهد که پروفایل‌های مشخص را در دسته‌های پاتولوژیک آشکار می‌کند. در بیمار نمونه شکل (۷)، ضایعات پری و نتریکولار که مقادیر نفوذ پایین‌تر را نشان می‌دهند در حالی که ضایعات پاراونتریکولار عمق‌های بالاتر با تغییرپذیری قابل توجهی را نشان دادند، که مکانیسم‌های پاتوفیزیولوژیک الگوهای تشکیل ضایعه پری و نولار را منعکس می‌کند.



(ب)

(الف)



(د)

(ج)



شکل (۷): تحلیل عمق نفوذ ضایعات. (الف) عمق نفوذ ضایعات فردی بر اساس دسته: پری و نتریکولار (قرمز)، پاراونتریکولار (نارنجی)، جاکستاکورتیکال (زرد). (ب) توزیع آماری بر اساس دسته. (ج) توزیع نفوذ برش محور. (د) سهم نسبی نفوذ بر اساس نوع ضایعه.


تغییرات منطقه‌ای در سطوح محوری تفاوت‌های قابل توجه بین‌دسته‌ای را در مقادیر میان نفوذ نشان دادند. مشابه شکل (۷)، تحلیل‌های تکمیلی از عمق نیمکره‌ای و شدت‌های روشنایی نرمال شده می‌توان ارائه نمود. تحلیل عمق نیمکره‌ای، مشخصه‌یابی فضایی نسبت به مرزهای سطح مغز را فراهم می‌کند. تحلیل شدت روشنایی، پروفایل‌های روشنایی متمایز را در دسته‌های ضایعه آشکار می‌کند که با مکانیسم‌های پاتوفیزیولوژیک متمایز در دسته‌های آناتومیک مرتبط است.

۳/۳. نتایج تحلیل گذر زمانی

چارچوب تحلیل گذر زمانی به‌طور موفقیت‌آمیزی قابلیت پایش طولی پیشرفت بیماری را از طریق یکپارچه‌سازی خودکار داده‌های تصویربرداری چندزمانی نشان داد. شکل (۸) نمونه‌ای جامع از تحلیل طولی برای یک بیمار نمونه با سه نقطه زمانی متوالی را ارائه می‌دهد که قابلیت سیستم در ردیابی تغییرات بار ضایعه و شاخص‌های نوروآناتومیک در گذر زمان را نشان می‌دهد.

در بیمار نمونه، تحلیل طولی پایداری قابل توجهی را در مشخصه‌های بار ضایعه آشکار می‌کند. تغییرات مشاهده‌شده در پارامترهای کمی کمتر از $\pm 10\%$ درصد باقی ماند که با توجه به خطاهای سیستماتیک ذاتی ناشی از تغییرپذیری تصویربرداری و عملکرد مدل‌های بخش‌بندی، روند تقریباً ثابتی برای وضعیت بیماری نشان می‌دهد. این پایداری نشان‌دهنده فعالیت بیماری محدود و عدم پیشرفت قابل توجه ضایعات در طول دوره زمانی مشاهده‌شده است.

تحلیل کمی تغییرات بین نقاط زمانی متوالی اطلاعات ارزشمندی برای ارزیابی بالینی فراهم می‌کند. نمودارهای خطی زمانی به‌طور واضح اندازه و جهت تغییرات را در هر دسته‌بندی نورواناتومیک نشان می‌دهند و به متخصصان امکان می‌دهند تا به‌سرعت الگوهای پیشرفت یا ثبات بیماری را شناسایی کنند. این قابلیت تحلیل گذر زمانی خودکار، تصمیم‌گیری بالینی را با فراهم کردن تجسم‌های قابل تفسیر و معیارهای کمی دقیق از پویایی بیماری در طول زمان، به‌طور قابل توجهی پشتیبانی می‌کند.



شکل (۸): تحلیل طولی چندپارامتری برای یک بیمار نمونه با سه نقطه زمانی. تجسم در قالب گرید 2×2 ارائه شده است: (بالا چپ) نمودار زمانی تعداد ضایعات برای زیرگروه‌های پری و نتریکولار، پاراونتریکولار، جاکستاکورتیکال و کل ضایعات؛ (بالا راست) تغییرات مساحت ضایعات با همین تفکیک دسته‌بندی؛ (پایین چپ) تغییرات عمق نفوذ ضایعات با همین تفکیک دسته‌بندی؛ (پایین راست) تخمین حجمی سیستم بطنی به‌عنوان شاخص آتروفی مغزی.

۳/۴. نتایج اعتبارسنجی بالینی

۳/۴/۱. همبستگی متخصصان و ارزیابی دقت

اعتبارسنجی بالینی با مشارکت سه نورورادیولوژیست، در نه مورد انتخابی عملکرد استثنایی را نشان داد. چارچوب پیشنهادی همبستگی عالی با ارزیابی‌های متخصصان به دست آورد: ضایعات پری و نتریکولار ($MAE = 1.7$, $r = 0.979$)، ضایعات پاراونتریکولار ($MAE = 1.4$, $r = 0.989$)، و ضایعات جاکستاکورتیکال ($MAE = 0.7$, $r = 0.975$). دقت کلی بخش‌بندی، کامل بودن تشخیص، و دقت طبقه‌بندی به ترتیب 4.3 ± 0.4 ، 4.8 ± 0.3 ، و 4.6 ± 0.4 در مقیاس‌های مرتبط با بالین ۵ نقطه‌ای لیکرت رتبه‌بندی شدند.

۳/۴/۲. کارایی گردش کار و پیاده‌سازی بالینی

ارزیابی متخصصان بهبودهای قابل توجه گردش کار را با کاهش 73.9% زمان تحلیل 11.0 ± 2.9 به 3.0 ± 1.4 دقیقه در هر مورد، ($p < 0.01$) نشان داد. ارزیابی مقایسه‌ای با استفاده از مقیاس‌های لیکرت ۵ نقطه‌ای عملکرد برتر را در سرعت ($+3.0$)، کامل

بودن تشخیص ضایعه ($+0.3$)، ارائه جزئیات کمی ($+1.0$)، و تکرارپذیری ($+1.0$) نشان داد، در حالی که دقت طبقه‌بندی بالینی قابل قبول (-0.3) را حفظ کرد.

زمان پردازش 11.2 ± 22.4 ثانیه، پشتیبانی تصمیم‌گیری بالینی لحظه‌ای را در طول ارزیابی تشخیصی امکان‌پذیر می‌سازد. اجماع متخصصان (100% توافق) تشخیص جامع ضایعه، گردش کار زمان کارآمد، تکرارپذیری ثابت، و دقت کمی را به عنوان نقاط قوت کلیدی شناسایی کرد. همه متخصصان چارچوب را آماده برای پیاده‌سازی بالینی رتبه‌بندی کردند، که به رتبه‌بندی کلی استثنایی 9.0 ± 0.0 در مقیاس ۱۰ نقطه‌ای با توافق کامل بین ارزیاب منجر شد، که قابلیت‌های جامع و سودمندی بالینی را برای بهبود گردش کارهای تشخیصی MS منعکس می‌کند.

۴. بحث

این مطالعه یک چارچوب محاسباتی جامع برای مشخصه‌یابی کمی ضایعات MS ارائه می‌دهد که محدودیت‌های اساسی در عملکرد تصویربرداری عصبی فعلی را با یکپارچه‌سازی اصلاح ضایعات آگاه به زمینه با طبقه‌بندی مبتنی بر اطلاعات نورواناتومیک بررسی می‌کند. رویکرد ما یک پیشرفت قابل توجه را از طریق یکپارچگی سیستماتیک پنج حوزه کمی (تعداد، مساحت، عمق نفوذ، موقعیت نیمکره‌ای و شدت) در یک سیستم طبقه‌بندی مبتنی بر اطلاعات نورواناتومیک که ضایعات پری و نتریکولار، جاکستاکورتیکال و ماده سفید عمیق را بر اساس اهمیت پاتوفیزیولوژیک طبق معیارهای مک‌دونالد ۲۰۱۷ تمایز می‌دهد، ارائه می‌کند. مقایسه نظام‌مند با رویکردهای موجود، تمایزهای اساسی چارچوب پیشنهادی را در چند محور کلیدی آشکار می‌سازد. در حوزه بخش‌بندی خودکار ضایعات، روش‌های مبتنی بر شبکه‌های عصبی کانولوشنال [۱۴] و رویکردهای اجماع الگوریتمی [۱۶] دقت قابل قبولی در تشخیص ضایعات نشان داده‌اند، اما این روش‌ها عمدتاً مشخصه‌یابی کمی چندپارامتری را در پیوند با طبقه‌بندی نورواناتومیک مبتنی بر معیارهای تشخیصی ارائه نمی‌دهند. در حوزه پایش طولی، رویکردهای پیشرفته‌ای نظیر آنچه در [۲۲-۲۴] معرفی شده‌اند قابلیت ردیابی تغییرات را نشان داده‌اند، اما یکپارچه‌سازی سیستماتیک آن‌ها با تحلیل چندپارامتری همزمان در پنج حوزه کمی در یک چارچوب واحد، که هدف مستقیم پژوهش حاضر بوده، محدود بوده است. سیستم‌های بالینی مستقر که اکنون برای جمعیت‌های بزرگ بیماران به کار گرفته شده‌اند [۲۵] نیز اغلب بر معیارهای ساده‌تری چون تعداد و حجم کلی ضایعات تمرکز دارند و از مشخصه‌یابی دقیق فضایی مبتنی بر توپوگرافی نورواناتومیک — که بنیان معیارهای پراکندگی مکانی مک‌دونالد ۲۰۱۷ را تشکیل می‌دهد — محدودند. از سوی دیگر، رویکردهایی که به تحلیل الگوی فضایی پرداخته‌اند [۱۸-۲۰] اطلاعات توپوگرافی ارزشمندی ارائه داده‌اند، اما یکپارچه‌سازی آن‌ها با پایش طولی خودکار و قابلیت تفسیر مستقیم بالینی در گردش کار رادیولوژیک بررسی نشده است. مزیت متمایز چارچوب حاضر در یکپارچه‌سازی همزمان این سه حوزه — بخش‌بندی، مشخصه‌یابی چندپارامتری، و پایش طولی — در یک سامانه واحد با خروجی استانداردشده و قابل تفسیر بالینی نهفته است که ضرایب همبستگی بالاتر از ۰.۹۷۵ را در تمام دسته‌های نورواناتومیک و کاهش ۷۳.۹٪ زمان تحلیل نسبت به ارزیابی متعارف به دست می‌آورد. محدودیت اصلی در مقایسه با برخی رویکردهای موجود، تکیه بر تصویربرداری دوبعدی FLAIR به‌تنهایی و فقدان اعتبارسنجی چندمرکزی است که در بخش محدودیت‌ها به تفصیل مطرح شده است.

نوآوری اصلی در الگوریتم اصلاح ضایعات آگاه به زمینه ما نهفته است که ابهام ذاتی در رویکردهای طبقه‌بندی پیکسل به پیکسل را با پیاده‌سازی تحلیل مجاورت فضایی و معیارهای نزدیکی بطنی که پاتوفیزیولوژی زیربنایی را که در آن ضایعات MS از فضاها پری و نولار منشأ می‌گیرند و عمود بر رابط‌های CSF گسترش می‌یابند بهتر منعکس می‌کنند، بررسی می‌کند. برخلاف رویکردهای متعارف که هاپراینتنسیت‌های ماده سفید را به‌طور یکنواخت در نظر می‌گیرند، چارچوب ما محاسبات فاصله ژئودزیک و محدودیت‌های مرز آناتومیک را پیاده‌سازی می‌کند تا اطمینان حاصل شود که طبقه‌بندی ضایعه دانش نوروپاتولوژیک مستقر را منعکس می‌کند، دقت تشخیصی را افزایش می‌دهد و از تشخیص افتراقی از بیماری‌های مشابه MS پشتیبانی می‌کند.

در مقایسه با رویکردهای سنتی که بر حجم ضایعه یا معیارهای ساده تعداد تمرکز می‌کنند [۱۰]، چارچوب ما مشخصه‌یابی مورفومتریک و فضایی جامعی را فراهم می‌کند که ناهمگونی ضایعه را در ابعاد متعدد ثبت می‌کند. در حالی که عملکرد بخش‌بندی قابل مقایسه با رویکردهای اخیر یادگیری عمیق را به دست می‌آورد (ضرایب همبستگی < 0.985 ، $p < 0.01$ در همه دسته‌های ضایعه)، چارچوب ما بر تفسیرپذیری بالینی و کمی‌سازی استاندارد همسو با معیارهای پراکندگی در مکان که اساسی برای تشخیص MS هستند تأکید می‌کند.

قابلیت تحلیل گذر زمانی خودکار یک مزیت متمایز چارچوب ما را نشان می‌دهد که امکان پایش طولی سیستماتیک پیشرفت بیماری و پاسخ درمانی را فراهم می‌کند. از طریق یکپارچه‌سازی داده‌های چندزمانی و محاسبه خودکار تغییرات مطلق و نسبی در همه پارامترهای کمی، چارچوب معیارهای استاندارد برای ارزیابی فعالیت بیماری را ارائه می‌دهد. نتایج نشان داد که تغییرات کمتر از $\pm 10\%$ درصد می‌تواند با توجه به تغییرپذیری سیستماتیک تصویربرداری و عملکرد مدل، نشان‌دهنده پایداری بالینی باشد، که مرجع مهمی برای تفسیر تغییرات معنادار در عملکرد بالینی فراهم می‌کند.

ارزیابی متخصصان بهبودهای قابل توجهی را در کارایی گردش کار بالینی با کاهش 73.9% زمان تحلیل در حالی که دقت بخش‌بندی بالا (4.3 ± 0.4 در مقیاس ۵ نقطه‌ای) حفظ شد، نشان داد. توافق کامل بین ارزیاب (90.0 ± 0.0 رتبه‌بندی چارچوب) در میان متخصصان با سطوح تجربه متفاوت نشان می‌دهد که چارچوب ما می‌تواند ارزیابی ضایعات MS را در محیط‌های عملکرد مختلف استانداردسازی کند، به‌ویژه برای رادیولوژیست‌های عمومی و نورولوژیست‌ها با تخصص محدود در تصویربرداری MS ارزشمند است. معیارهای کمی نقاط پایانی استاندارد برای پایش طولی و کاربردهای کارآزمایی بالینی فراهم می‌کنند و تشخیص تغییرات ظریف در ویژگی‌های ضایعه را که ممکن است قبل از تغییرات حجمی به‌عنوان شاخص‌های اولیه پاسخ درمانی یا پیشرفت بیماری رخ دهند، امکان‌پذیر می‌سازند.

چندین محدودیت شایسته توجه هستند. تکیه بر رویکردهای بخش‌بندی دوبعدی و تصویربرداری FLAIR به‌تنهایی، در حالی که به‌صورت بالینی استاندارد است، ممکن است دقت روابط فضایی سه‌بعدی و ترکیب توالی‌های مکمل را محدود کند. پایگاه داده تک‌مرکزی با پارامترهای استاندارد اکتساب 1.5 تسلا، تعمیم‌پذیری چارچوب را در تنوع سخت‌افزاری و پروتکلی محدود می‌سازد. هرچند در مرحله آموزش مدل بخش‌بندی پایه [۲۷]، از داده‌های یک مجموعه عمومی برای تقویت انعطاف‌پذیری مدل بهره گرفته شد، ارزیابی سیستماتیک عملکرد بر روی اسکنرهای مختلف (از جمله ۳ تسلا)، پروتکل‌های متفاوت اکتساب، و مراکز تصویربرداری متعدد، برای تأیید کارایی بالینی در شرایط واقعی ضروری است. اعتبارسنجی چندمرکزی که پوشش جمعیتی و تنوع تجهیزاتی گسترده‌تری را شامل شود، به‌عنوان اولویت اول توسعه آینده تعریف شده و انجام آن برای استقرار بالینی گسترده‌تر این چارچوب اجتناب‌ناپذیر است. علاوه بر این، پروتکل اعتبارسنجی بالینی با مشارکت سه نورورادیولوژیست و نه بیمار انجام شده است که اگرچه نتایج امیدوارکننده‌ای به دست داده، اما حجم نمونه محدود این بخش را باید در تفسیر نتایج مدنظر قرار داد؛ مطالعات آینده باید اعتبارسنجی بالینی را با تعداد بیماران و ارزیابان بیشتری تکرار کنند. همچنین، نمایش قابلیت تحلیل گذر زمانی در مقاله حاضر بر اساس یک بیمار نمونه با سه نقطه زمانی ارائه شده است. اگرچه این نمایش، کارایی مفهومی و فنی سیستم را نشان می‌دهد، اعتبارسنجی کمی گسترده‌تر این قابلیت با مجموعه داده‌های طولی بزرگ‌تر و چندمرکزی برای تأیید حساسیت سیستم در تشخیص تغییرات ظریف بیماری در برنامه‌های آینده تعریف شده است.

توسعه آینده باید بر یکپارچگی توالی‌های تصویربرداری اضافی شامل تصویربرداری تانسور انتشار، تصویربرداری وزن‌دهی شده به پذیرفتاری مغناطیسی، و تصویربرداری انتقال مغناطیسی برای فوتوتایپ‌سازی جامع ضایعه تمرکز کند. برقراری همبستگی بین نشانگرهای زیستی تصویربرداری کمی و معیارهای پیامد بالینی، از جمله پیشرفت ناتوانی و عملکرد شناختی، ارتباط بالینی را اعتبارسنجی می‌کند و تفسیر در عملکرد بالینی را راهنمایی می‌کند. توسعه مدل‌های پیش‌بینی که از داده‌های طولی برای پیش‌آگهی مسیر بیماری استفاده می‌کنند، می‌تواند تصمیم‌گیری درمانی شخصی‌شده را بیشتر پشتیبانی کند.

این چارچوب محاسباتی جامع تحلیل پیشرفته تصاویر و کاربرد بالینی را پیوند می‌دهد و استانداردهای جدیدی را برای مشخصه‌سازی کمی ضایعات MS ایجاد می‌کند. یکپارچگی قابلیت‌های بخش‌بندی خودکار، تحلیل چندپارامتری، و پایش طولی، پیامدهای قابل توجهی برای کاربردهای پزشکی دقیق، بهینه‌سازی کارآزمایی بالینی، و بهبود پیامدهای بیمار دارد.

۵. نتیجه‌گیری

این مطالعه یک چارچوب یادگیری عمیق جامع از ابتدا تا انتها برای مشخصه‌یابی کمی خودکار ضایعات MS ارائه می‌دهد که به‌طور موفقیت‌آمیزی ارزیابی‌های رادیولوژیک کیفی را به معیارهای استاندارد و تکرارپذیر همسو با معیارهای تشخیصی مک‌دونالد ۲۰۱۷ تبدیل می‌کند. رویکرد مبتنی بر اطلاعات نوروآناتومیک ما، اصلاح ضایعات آگاه به زمینه را با تحلیل چندپارامتری در پنج حوزه کمی یکپارچه می‌کند و نشانگرهای زیستی مرتبط با بالین را که فراتر از ارزیابی‌های حجمی متعارف می‌روند فراهم می‌کند. یکپارچه‌سازی قابلیت تحلیل گذر زمانی خودکار، امکان پایش طولی سیستماتیک پیشرفت بیماری و پاسخ درمانی را فراهم می‌کند که برای مدیریت بالینی MS و کاربردهای کارآزمایی بالینی ضروری است. چارچوب، نتایج اعتبارسنجی استثنایی با ضرایب همبستگی بیش از ۰.۹۸۵ در همه دسته‌های ضایعه به دست آورد و سودمندی بالینی قابل توجهی را از طریق کاهش ۷۳.۹٪ زمان تحلیل در حالی که دقت تشخیصی بالا حفظ شد، نشان داد. رتبه‌بندی اجماع متخصصان 90.0 ± 0.0 آمادگی برای پیاده‌سازی بالینی را تایید می‌کند. این چارچوب محاسباتی، استانداردهای جدیدی را برای تصویربرداری کمی MS ایجاد می‌کند و پیامدهای قابل توجهی برای کاربردهای پزشکی دقیق، بهینه‌سازی کارآزمایی بالینی، و بهبود پیامدهای بیمار از طریق نشانگرهای زیستی تصویربرداری هدفمند دارد.

دسترسی داده‌ها و مواد

مجموعه داده و پیاده‌سازی‌های استفاده شده در این مطالعه به دلیل ملاحظات حریم خصوصی، سیاست‌های نهادی، و توسعه در حال انجام برای کاربردهای تجاری، به‌صورت عمومی در دسترس نیستند. ما یک سرویس مبتنی بر وب را که چارچوب پیشنهادی را پیاده‌سازی می‌کند، توسعه داده‌ایم که در <https://www.inscans.com> قابل دسترسی است. این پلتفرم در حال حاضر در نسخه آلفا با دسترسی محدود است که نیازمند تأیید مدیریتی برای ایجاد حساب کاربری است. این سرویس تحت توسعه فعال برای افزایش قابلیت‌ها و ابزارها برای کاربردهای بالینی و استفاده متخصصان است. یک ویدئوی نمایشی جامع که کل گردش کار از بارگذاری DICOM تا تولید گزارش PDF نهایی را نشان می‌دهد، به‌عنوان ویدئوی تکمیلی SI ارائه شده است که رابط کاربری را در کنار تجسم پردازش‌های پیش‌پرده نشان می‌دهد. درخواست‌های دسترسی و پرس‌وجوهای همکاری باید به نویسندگان ارسال شود. هرگونه پرس‌وجو در مورد دسترسی به داده‌ها، جزئیات پیاده‌سازی، توضیحات روش‌شناسی، یا همکاری‌های تحقیقاتی بالقوه باید به نویسندگان مسئول هدایت شود. با این حال، بخشی از داده‌های پایه این پژوهش، شامل تصاویر MRI چندتوالی و ماسک‌های بخش‌بندی دستی سه کلاسه ۱۰۰ بیمار MS (مجموعه داده MS3SEG)، پیش‌تر به‌صورت عمومی منتشر شده است [۳۲]. لازم به ذکر است که این مجموعه داده عمومی شامل داده‌های تکرار زمانی نمی‌شود و پوشش کامل داده‌های مورد استفاده در تحلیل طولی مقاله حاضر را ندارد.

سپاسگزاری

نویسندگان از مهندس مهرداد رهبرپور، مهندس آزاد احمدی و دکتر آیدین قلعه‌اسدی، همکاران مرکز تصویربرداری پزشکی گلگشت، به‌خاطر همکاری ایشان در جمع‌آوری داده‌ها قدردانی می‌کنند. همچنین از ارزیاب‌های متخصصان، دکتر امیررضا جهانشاهی و دکتر شهاب عبدی، به‌دلیل مشارکت ارزشمندشان در این مطالعه، تشکر ویژه به‌عمل می‌آوریم. نویسندگان استفاده از

Claude Sonnet 4 (Anthropic، دسترسی در آگوست ۲۰۲۵) را برای کمک در آماده‌سازی نسخه خطی، شامل پشتیبانی نگارش و کمک به قالب‌بندی، اعلام می‌کنند. تمامی محتوای تولید شده توسط هوش مصنوعی به‌دقت توسط نویسندگان بازرینی، ویرایش و اعتبارسنجی شده است تا از صحت و مناسب بودن آن برای زمینه علمی اطمینان حاصل شود.

تأمین مالی

این پژوهش هیچ گونه کمک مالی اختصاصی از سوی سازمان‌های تأمین اعتبار در بخش‌های دولتی، تجاری یا غیرانتفاعی دریافت نکرده است.

تعارض منافع

نویسندگان اعلام می‌کنند که هیچ گونه تعارض منافی ندارند.

تأییدیه اخلاقی و رضایت‌نامه شرکت در پژوهش

این مطالعه توسط کمیته اخلاق در پژوهش دانشگاه علوم پزشکی تبریز تأیید شده است (IR.TBZMED.REC.1402.902). رضایت‌نامه کتبی آگاهانه از تمامی بیماران برای شرکت در این مطالعه گذشته‌نگر اخذ گردید. تمامی روش‌های اجرا شده مطابق با استانداردهای اخلاقی کمیته پژوهشی مؤسسه و با بیانیه هلسینکی ۱۹۶۴ و اصلاحیه‌های بعدی آن بوده است.

رضایت‌نامه آگاهانه

رضایت‌نامه کتبی آگاهانه برای انتشار از تمامی بیماران جهت استفاده از داده‌های تصویربرداری MRI ناشناس شده آنها در این مطالعه اخذ شد.

۶. مراجع

1. C. Walton et al., "Rising Prevalence of Multiple Sclerosis worldwide: Insights from the Atlas of MS, Third Edition," Multiple Sclerosis Journal, vol. 26, no. 14, pp. 1816–1821, 2020.
2. J. M. Wardlaw et al., "Neuroimaging standards for research into small vessel disease and its contribution to ageing and neurodegeneration," The Lancet Neurology, vol. 12, no. 8, pp. 822–838, 2013.
3. C. Lucchinetti, W. Brück, J. Parisi, B. Scheithauer, M. Rodriguez, and H. Lassmann, "Heterogeneity of multiple sclerosis lesions: implications for the pathogenesis of demyelination," Annals of neurology, vol. 47, no. 6, pp. 707–17, 2000.
4. Matthias Bussas et al., "Gray matter atrophy in relapsing-remitting multiple sclerosis is associated with white matter lesions in connecting fibers," Multiple Sclerosis Journal, vol. 28, no. 6, pp. 900–909, 2021.
5. W. J. Brownlee, T. A. Hardy, F. Fazekas, and D. H. Miller, "Diagnosis of multiple sclerosis: progress and challenges," The Lancet, vol. 389, no. 10076, pp. 1336–1346, 2017.
6. M. Filippi et al., "Intra- and inter-observer agreement of brain MRI lesion volume measurements in multiple sclerosis," Brain, vol. 118, no. 6, pp. 1593–1600, 1995.
7. M. Ward and M. D. Goldman, "Epidemiology and Pathophysiology of Multiple Sclerosis," CONTINUUM: Lifelong Learning in Neurology, vol. 28, no. 4, pp. 988–1005, 2022.
8. M. Homssi et al., "Evaluation of the Statistical Detection of Change Algorithm for Screening Patients with MS with New Lesion Activity on Longitudinal Brain MRI," American Journal of Neuroradiology, vol. 44, no. 6, pp. 649–655, 2023.
9. A. Rovira et al., "MAGNIMS consensus guidelines on the use of MRI in multiple sclerosis—clinical implementation in the diagnostic process," Nature Reviews Neurology, vol. 11, no. 8, pp. 471–482, 2015.
10. M. Filippi et al., "Assessment of lesions on magnetic resonance imaging in multiple sclerosis: practical guidelines," Brain, vol. 142, no. 7, pp. 1858–1875, 2019.

11. F. L. Rosa et al., "Cortical lesions, central vein sign, and paramagnetic rim lesions in multiple sclerosis: Emerging machine learning techniques and future avenues," *NeuroImage Clinical*, vol. 36, pp. 103205–103205, 2022.
12. K. Juluru et al., "Integrating AI Algorithms into the Clinical Workflow," *Radiology: Artificial Intelligence*, vol. 3, no. 6, p. e210013, 2021.
13. Y. Ma et al., "Multiple Sclerosis Lesion Analysis in Brain Magnetic Resonance Images: Techniques and Clinical Applications," *IEEE Journal of Biomedical and Health Informatics*, vol. 26, no. 6, pp. 2680–2692, 2022.
14. R. E. Gabr et al., "Brain and lesion segmentation in multiple sclerosis using fully convolutional neural networks: A large-scale study," *Multiple sclerosis (Houndmills, Basingstoke, England)*, p. 1352458519856843, 2019.
15. S. Chakrabarty, A. Sotiras, M. Milchenko, P. LaMontagne, M. Hileman, and D. Marcus, "MRI-based Identification and Classification of Major Intracranial Tumor Types by Using a 3D Convolutional Neural Network: A Retrospective Multi-institutional Analysis," *Radiology: Artificial Intelligence*, vol. 3, no. 5, p. e200301, 2021.
16. P. De et al., "Consensus of algorithms for lesion segmentation in brain MRI studies of multiple sclerosis," *Scientific Reports*, vol. 14, no. 1, 2024.
17. C. Yu, B. Mohajer, and J. Eng, "External Validation of Deep Learning Algorithms for Radiologic Diagnosis: A Systematic Review," *Radiology: Artificial Intelligence*, vol. 4, no. 3, 2022.
18. C.-L. Phuah et al., "Association of Data-Driven White Matter Hyperintensity Spatial Signatures with Distinct Cerebral Small Vessel Disease Etiologies," *Neurology*, vol. 99, no. 23, pp. e2535–e2547, 2022.
19. C. Tur et al., "Spatial patterns of brain lesions assessed through covariance estimations of lesional voxels in multiple Sclerosis: The SPACE-MS technique," *NeuroImage: Clinical*, vol. 33, pp. 102904–102904, 2022.
20. J. Jiménez-Balado, F. Corlier, C. Habeck, Y. Stern, and T. Eich, "Effects of white matter hyperintensities distribution and clustering on late-life cognitive impairment," *Scientific Reports*, vol. 12, no. 1, 2022.
21. D. Yang et al., "Segmentation of Subtraction Images for the Measurement of Lesion Change in Multiple Sclerosis," *American Journal of Neuroradiology*, vol. 29, no. 2, pp. 340–346, 2008.
22. G. Cooper et al., "Longitudinal analysis of T1w/T2w ratio in patients with multiple sclerosis from first clinical presentation," *Multiple Sclerosis Journal*, vol. 27, no. 14, pp. 2180–2190, 2021.
23. Mário João Fartaria, T. Kober, C. Granziera, and Meritxell Bach Cuadra, "Longitudinal analysis of white matter and cortical lesions in multiple sclerosis," *NeuroImage. Clinical*, vol. 23, pp. 101938–101938, 2019.
24. S. Hitziger, W. X. Ling, T. Fritz, T. D'Albis, A. Lemke, and J. Grilo, "Triplanar U-Net with lesion-wise voting for the segmentation of new lesions on longitudinal MRI studies," *Frontiers in Neuroscience*, vol. 16, 2022.
25. S. P. Thakur, M. K. Schindler, M. Bilello, and S. Bakas, "Clinically Deployed Computational Assessment of Multiple Sclerosis Lesions," *Frontiers in Medicine*, vol. 9, 2022.
26. M. B. Bawil, M. Shamsi, A. S. Babil, and S. Danishvar, "Specialized gray matter segmentation via a generative adversarial network: application on brain white matter hyperintensities classification," *Frontiers in Neuroscience*, vol. 18, 2024.
27. M. B. Bawil, M. Shamsi, and A. S. Babil, "AI-Driven Multi-parametric MS Lesion Analysis from T2-FLAIR Imaging: a Clinical Decision Support Framework for Neuroradiology," *Journal of Imaging Informatics in Medicine*, 2026.
28. J. Thompson et al., "Diagnosis of Multiple sclerosis: 2017 Revisions of the McDonald Criteria," *The Lancet Neurology*, vol. 17, no. 2, pp. 162–173, 2018.
29. X. Lladó et al., "Segmentation of multiple sclerosis lesions in brain MRI: A review of automated approaches," *Information Sciences*, vol. 186, no. 1, pp. 164–185, 2012.
30. R. Zivadinov and R. Bakshi, "Role of MRI in multiple sclerosis II: brain and spinal cord atrophy," *Frontiers in Bioscience*, vol. 9, no. 1–3, pp. 647–647, 2004.
31. F. Barkhof et al., "Comparison of MRI criteria at first presentation to predict conversion to clinically definite multiple sclerosis," *Brain*, vol. 120, no. 11, pp. 2059–2069, 1997.
32. M. B. Bawil, M. Shamsi, A. Ghalehasadi, A. F. Jafargholkhanloo, and A. S. Babil, "A Multiple Sclerosis MRI Dataset with Tri-Mask Annotations for Lesion Segmentation," *Scientific Data*, 2026.



Sahand University
of Technology

DOR:

[20.1001.1.23223146.1405.12.2.3.2](https://doi.org/10.1001.1.23223146.1405.12.2.3.2)

**Journal of Nonlinear
Systems in Electrical
Engineering**

Vol. 12, No. 2

Autumn and Winter 2025

ISSN: 2322 – 3146

<http://jnsee.sut.ac.ir>

Drift Detection and Compensation in Semiconductor Gas Sensors Using Lightweight Deep Learning Models Deployable on the Edge

Amire Seyedfaraji*

Department of Electrical Engineering, Faculty of Engineering, Alzahra
University, Tehran, Iran

*Corresponding author email: sfaraji@alzahra.ac.ir

Abstract

This paper presents a robust hybrid controller based on passivity-based control (PBC) for output voltage regulation of a DC-DC boost converter operating in Continuous Conduction Mode (CCM). The proposed scheme integrates PBC within a cascade structure featuring a PI voltage loop to mitigate the limitations of individual methods. Due to the non-minimum phase nature of the boost converter, voltage regulation is achieved indirectly via inductor reference current tracking. This reference current is generated by the outer PI loop, while the inner PBC loop ensures stability and fast dynamic performance in the presence of disturbances and parametric uncertainties. System dynamic equations are derived using an averaged model that accounts for parasitic elements, and the controller is designed based on passivity stability theory. To validate the proposed method, a laboratory prototype was implemented, and the controller's performance was evaluated under five distinct scenarios, including step changes in reference voltage, load variations, input voltage fluctuations, and parameter uncertainties. Simulation and experimental results demonstrate significant improvements in stability, dynamic response, and steady-state error reduction compared to a pure passivity-based controller, confirming the robustness and effectiveness of the proposed hybrid approach under various operating conditions.

Keywords

Boost Converter; Passivity-based Control; Cascade Control; Robust Stability

1. Short Introduction

DC-DC converters play a vital role in modern technologies such as electric vehicles due to their high efficiency. However, the limitations of classical controllers in handling parametric variations have led to the development of advanced control strategies such as sliding mode control. While these methods address certain challenges, they do not always guarantee the inherent stability of nonlinear systems. Consequently, Passivity-Based Control (PBC) has emerged as an efficient solution for voltage regulation owing to its design simplicity and robustness. Furthermore, numerous studies have integrated PBC with other control techniques to enhance the performance of energy storage systems.

2. Proposed Work

To address the inherent non-minimum phase characteristics and stability challenges of DC-DC boost converters, this study proposes a robust hybrid control strategy that regulates the output voltage indirectly through inductor current tracking. The system dynamics are modeled using the Euler-Lagrange method, incorporating parasitic elements such as equivalent series resistances and semiconductor voltage drops to ensure a realistic representation. The control architecture integrates a Passivity-Based Controller (PBC) within a cascaded structure featuring a Closed-Loop PI (CCLPI) voltage regulator. In this configuration, the inner PBC loop utilizes energy shaping and damping injection principles to guarantee global asymptotic stability and fast dynamic response, while the outer PI loop generates the reference current to eliminate steady-state errors caused by model inaccuracies or load variations. Theoretical analysis based on Lyapunov stability theory confirms that the system maintains Input-to-State Stability (ISS) even in the presence of bounded parameter uncertainties. To validate this approach, a laboratory prototype was built and several tests were carried out. Experimental and simulation results across five scenarios, including step changes in reference voltage, load variations, input voltage fluctuations, and parameter uncertainties, demonstrate the superiority of the proposed CCLPI-PBC over standard PBC. Specifically, the proposed method successfully rejected severe disturbances, such as a 25% drop in input voltage and significant load changes, under conditions where the standard PBC failed to maintain regulation. Furthermore, sensitivity analysis revealed that under a drastic reduction in inductance from 10mH to 1mH, the hybrid controller reduced the steady-state error from 2.55V to a negligible 0.01V, confirming its robustness and precise tracking capabilities.

3. Conclusion

This study developed a hybrid CCLPI-PBC scheme to overcome the non-minimum phase challenges of boost converters via indirect current tracking. Experimental results confirm that, unlike classical PBC, the proposed method eliminates steady-state errors under severe fluctuations and maintains stability against significant parametric uncertainties, such as a reduction in inductance. Considering implementation simplicity and high robustness, this approach offers an efficient industrial solution for voltage-sensitive applications.

تشخیص و جبران رانش در سنسورهای گازی نیم‌رسانا با استفاده از مدل‌های یادگیری عمیق سبک و قابل استقرار روی سامانه‌های لبه

امیره سیدفرجی*

استادیار، مهندسی برق-الکترونیک، دانشگاه الزهرا (س)، تهران، ایران

آدرس پست الکترونیکی نویسنده مسئول: sfaraji@alzahra.ac.ir



دانشگاه صنعتی سهند

DOR:

[20.1001.1.23223146.1405.12.2.3.2](https://doi.org/10.1001.1.23223146.1405.12.2.3.2)

نشریه سالانه‌ی غیرخطی «مندی برق»

دوره ۱۲ - شماره ۲

پاییز و زمستان ۱۴۰۴

صفحات ۴۷ الی ۷۲

ISSN: 2322-3146

<http://jnsee.sut.ac.ir>

تاریخ پذیرش: ۱۴۰۵/۶/۳

تاریخ بازنگری: ۱۴۰۵/۵/۲۱

تاریخ ارسال: ۱۴۰۵/۳/۲۹

چکیده

واژه‌های کلیدی

حسگر گازی نیم‌رسانا

رانش

یادگیری عمیق سبک

جبران رانش

حسگرهای گازی نیم‌رسانا به دلیل هزینه پایین و پاسخ سریع به‌طور گسترده در پایش محیطی استفاده می‌شوند. در سال‌های اخیر، پژوهشگران برای مقابله با چالش رانش این حسگرها، به روش‌های کالیبراسیون دوره‌ای و مدل‌های یادگیری عمیق پیچیده روی آورده‌اند. با این حال، کالیبراسیون سنتی نیازمند مداخله انسانی مداوم است و مدل‌های عمیق متعارف نیز به دلیل بار محاسباتی سنگین، قابلیت اجرا در سامانه‌های لبه را ندارند. در این مقاله، یک چارچوب یکپارچه و کم‌حجم برای تشخیص و جبران رانش در آرایه‌های حسگر گازی ارائه شده است که با تحلیل ویژگی‌های زمانی سیگنال و پایش آماری تغییر توزیع داده‌ها، عملکرد مدل را در سامانه‌های لبه پایدار می‌سازد. در چارچوب پیشنهادی، ابتدا سیگنال‌ها، پیش‌پردازش شده و سپس ویژگی‌های زمانی با شبکه‌های پیچشی یک‌بعدی سبک (ID-CNN) استخراج می‌شوند. برای شناسایی رانش در فضای ویژگی، از فاصله ماکسیمم واریانس و برای جبران اثر آن، یک روش انطباق دامنه خصمانه مبتنی بر زیرفضا استفاده شده است. معماری پیشنهادی با محدودیت‌های سخت‌افزاری سامانه‌های لبه سازگار است. نتایج ارزیابی نشان می‌دهد که مدل پیشنهادی با تنها ۱۲۸ هزار پارامتر، به دقت طبقه‌بندی ۹۱/۸ درصد دست یافته و با کاهش واگرایی کولبک-لایبلر به ۰/۱۳۷، پایداری و دقت سامانه‌های تشخیص گاز را در شرایط عملیاتی به‌طور قابل توجهی بهبود می‌دهد.

۱- مقدمه

با گسترش اینترنت اشیاء، تقاضا برای توسعه سامانه‌های هوشمند پایش محیطی مبتنی بر حسگرها افزایش چشمگیری یافته است [۱]. در این میان، حسگرهای گازی ساخته شده از نیم‌رساناهای اکسید فلزی متخلخل چندجزئی، به دلیل کارایی بالا، هزینه پایین تولید، ساختار فشرده، حساسیت بالا به طیف گسترده‌ای از گازها و زمان پاسخ‌دهی سریع، سهم عمده‌ای در توسعه سامانه‌های هوشمند گازسنجی و پایش محیطی پیدا کرده‌اند [۲، ۳]. بررسی مکانیزم‌های شیمیایی مقاومتی، پارامترهای عملیاتی و کاربردهای متنوع این دسته از حسگرها، جایگاه ویژه آن‌ها را در پایش‌های صنعتی و محیطی نشان می‌دهد [۳]. با این حال، استفاده عملیاتی از این حسگرها با چالش بزرگی به نام رانش^۱ مواجه است. پدیده‌ای فیزیکی-شیمیایی که رفتار حسگر را در طول زمان دستخوش تغییر کرده و در داده‌های حسگرهای گازی به وضوح مشاهده می‌شود [۴]. رانش به تغییرات سیستماتیک و تدریجی پاسخ حسگر در طول زمان گفته می‌شود، که حتی در شرایط محیطی و غلظت گاز ثابت نیز رخ می‌دهد [۴]. از منظر شیمی سطح، این پدیده عمدتاً ناشی از تغییرات ساختاری در لایه حساس، مسمومیت سطح حسگر توسط گونه‌های شیمیایی، یا نوسانات رطوبت و دماست که باعث تغییر در نرخ جذب و دفع گازها می‌شود [۵]. رانش حسگرها منجر به از دست رفتن تدریجی کالیبراسیون و کاهش شدید دقت سیستم در پایش‌های طولانی مدت می‌گردد، که این امر ضرورت توسعه روش‌های نوین برای شناسایی و جبران آن را دوچندان می‌کند.

در پایش کیفیت هوا، به‌ویژه در شبکه‌های پایش منطقه‌ای، پایداری حسگرها از اهمیت بالایی برخوردار است [۵، ۶]. تلاش‌های پیشین برای ارتقای عملکرد دستگاه‌های گازسنج کم‌هزینه در شرایط واقعی، عمدتاً بر روش‌های نگهداری، کالیبراسیون و بهبودهای فیزیکی حسگر متمرکز بوده‌اند [۶]. در همین راستا، بررسی مکانیزم‌های بنیادی در مواد حسگر گاز نیم‌رسانای اکسید فلزی آلائیده [۷] و نیز استفاده از مواد مهمان عامل‌دار برای بهبود پاسخ‌دهی حسگرها [۸] مورد توجه قرار گرفته است. با وجود اثربخشی این راهکارها در ارتقای عملکرد ذاتی حسگر، کالیبراسیون‌های فیزیکی دوره‌ای معمولاً مستلزم هزینه زیاد و مداخله مستمر انسانی هستند [۶]. از این رو، پژوهشگران به استفاده از روش‌های یادگیری ماشین روی آورده‌اند تا طول دوره اعتبار کالیبراسیون حسگرها را، بدون نیاز به کالیبراسیون مجدد فیزیکی، افزایش دهند [۹]. برای نمونه، مدل‌های ترکیبی مبتنی بر حافظه کوتاه‌مدت-بلندمدت (LSTM) و ماشین بردار پشتیبان (SVM) برای جبران رانش توسعه یافته‌اند [۱۰]. با این حال، پیچیدگی محاسباتی این مدل‌ها می‌تواند مانعی جدی برای پیاده‌سازی آن‌ها بر روی سخت‌افزارهای دارای منابع محدود و سامانه‌های محاسبات لبه باشد. به‌طور کلی، پژوهش‌های پیشین در مواجهه با پدیده رانش در حسگرهای گازی نیم‌رسانای اکسید فلزی (MOS) را می‌توان در دو دسته اصلی طبقه‌بندی کرد: راهکارهای مبتنی بر بهبود سخت‌افزاری و کالیبراسیون فیزیکی دوره‌ای [۶]، و روش‌های مبتنی بر جبران‌سازی نرم‌افزاری با استفاده از یادگیری ماشین و الگوریتم‌های یادگیری عمیق [۹، ۱۰]. اگرچه کالیبراسیون فیزیکی دوره‌ای می‌تواند دقت حسگر را بهبود دهد یا بازیابی کند، اجرای آن معمولاً مستلزم هزینه، توقف یا اختلال در پایش برخط و مداخله مستقیم انسانی است [۶]. در مقابل، روش‌های محاسباتی و یادگیری ماشین تلاش کرده‌اند بدون نیاز به کالیبراسیون فیزیکی مکرر، اثر رانش را در سیگنال خروجی خنثی کنند [۹، ۱۰]. با این حال، تحلیل روش‌های موجود نشان می‌دهد که مدل‌های سنتی یادگیری ماشین اغلب وابستگی شدیدی به ویژگی‌سازی دستی و پیش‌پردازش‌های پیچیده آماری دارند [۱۱-۱۳]. از سوی دیگر، مدل‌های ترکیبی مانند LSTM-SVM، با وجود توانایی در مدل‌سازی وابستگی‌های زمانی، در برخی پیکربندی‌ها، به حافظه و توان محاسباتی بیشتری نسبت به مدل‌های پیچشی سبک نیاز دارند [۱۴-۱۹]. از این رو، استقرار آن‌ها بر سخت‌افزارهای لبه با منابع محدود ممکن است با چالش مواجه شود [۱۷-۱۹].

¹ Drift

افزون بر این، بسیاری از روش‌های انطباق دامنه، عمدتاً بر هم‌ترازی توزیع‌ها تمرکز دارند و سازوکاری صریح برای تعیین زمان شروع رانش ارائه نمی‌کنند [۲۰-۲۹] و فرآیند جبران را بدون ارزیابی اولیه و آگرایی توزیع انجام می‌دهند. برای تبیین دقیق‌تر شکاف پژوهشی، جدول ۱ ویژگی‌های ساختاری و روش‌شناختی رویکردهای شاخص موجود را با چارچوب پیشنهادی این پژوهش مقایسه می‌کند.

همان‌طور که در جدول ۱ نشان داده شده است، رویکردهای پیشین یا با محدودیت بار محاسباتی شدید مواجه‌اند یا در استخراج خودکار ویژگی‌های زمانی و تشخیص هوشمند زمان وقوع رانش بدون نیاز به مداخله انسانی ناتوان هستند [۱۷، ۱۹، ۲۳-۲۹]. این مقایسه روش‌شناختی به وضوح نیاز به یک راهکار یکپارچه، تطبیقی و در عین حال سبک را نشان می‌دهد که بتواند بدون نیاز به داده‌های برچسب‌دار جدید در دامنه مقصد، رانش را در سطح ویژگی تشخیص داده و جبران کند [۱۶، ۲۰، ۲۱، ۲۳-۲۹].

جدول ۱- مقایسه ساختاری و روش‌شناختی رویکردهای مقابله با رانش حسگرهای گازی MOS با چارچوب پیشنهادی این پژوهش

رویکرد و مرجع	ساز و کار اصلی مقابله با رانش	نیاز به کالیبراسیون/داده مرجع جدید	استخراج ویژگی زمانی	قابلیت تشخیص تغییر توزیع (رانش)	مناسب بودن برای سامانه های لبه
بهبود سخت‌افزار [۶]	کنترل شرایط کارکرد و بازکالیبراسیون فیزیکی	بله؛ نیازمند کالیبراسیون دوره‌ای و فیزیکی	عمدتاً خارج از حسگر و با پردازش جانبی	محدود؛ فاقد پایش برخط رانش	قابل اجرا در سطح سخت‌افزار حسگر؛ فاقد قابلیت کالیبراسیون خودکار برخط
طول عمر کالیبراسیون [۲۹]	پایداری مدل یادگیری ماشین در برابر نوسانات	بله؛ نیازمند داده جدید برای بازآموزی مدل	دستی؛ پیش‌پردازش سیگنال	خیر؛ تمرکز بر مقاومت مدل است	متوسط؛ وابسته به حجم مدل انتخاب‌شده
مدل ترکیبی LSTM-SVM [۳۰]	ترکیب مدل LSTM و SVM چندکلاسه	بله؛ نیازمند داده‌های آموزشی نماینده دامنه‌ها	خودکار؛ توسط ساختار شبکه LSTM	خیر؛ فاقد سیستم تشخیص مجزا	با محدودیت؛ به دلیل هزینه محاسباتی و حافظه‌ای مدل ترکیبی
یادگیری گروهی طبقه‌بندها [۳۱]	ترکیب وزنی طبقه‌بندها در طول زمان	بله؛ نیازمند داده برچسب‌دار جدید برای آموزش	دستی؛ پیش‌پردازش آماري داده‌ها	خیر؛ عدم پایش زمان شروع رانش	با محدودیت قابل استقرار؛ مشروط به ظرفیت حافظه و توان اجرای هم‌زمان چند مدل
انطباق دامنه مبتنی بر ELM [۲۲]	هم‌ترازی داده‌ها در فضای ویژگی مشترک با ELM	خیر؛ انطباق بدون نظارت روی دامنه مقصد	دستی؛ نیازمند بردارهای ویژگی اولیه	بله؛ سنجش فاصله بین دامنه‌ها	قابل استقرار مشروط؛ استخراج سریع است، اما مرحله انطباق می‌تواند پرهزینه باشد
انطباق توزیع مشترک (JDA) [۲۰]	کاهش واگرایی توزیع‌های مشترک با الگوریتم JDA	خیر؛ انطباق بدون نظارت روی دامنه مقصد	دستی؛ وابستگی به ویژگی‌های آماری اولیه	بله؛ مدل‌سازی اختلاف توزیع‌ها	محدود از منظر استقرار برخط؛ به دلیل هزینه محاسباتی مرحله بهینه‌سازی
چارچوب پیشنهادی	ترکیب 1D-CNN سبک و انطباق خصمانه زیرفضا	خیر؛ انطباق بدون نظارت روی دامنه مقصد	خودکار؛ استخراج ویژگی با 1D- CNN	بله؛ پایش آماری با فاصله ماکسیمالیس	مناسب برای استقرار در لبه، مشروط به تأیید مصرف حافظه و توان روی سخت‌افزار هدف؛ زمان پاسخ گزارش شده: ۱۱/۴ میلی‌ثانیه

بر این اساس، در این پژوهش یک چارچوب سبک و هوشمند برای تشخیص و جبران رانش در آرایه‌های حسگر گازی MOS ارائه شده است که به طور ویژه برای اجرا بر روی سخت‌افزارهای لبه با منابع محاسباتی و حافظه محدود طراحی شده است. در روش پیشنهادی، ابتدا سیگنال‌های خام پیش‌پردازش شده و سپس ویژگی‌های زمانی آن‌ها با استفاده از یک شبکه عصبی پیچشی یک‌بعدی^۱ (1D-CNN) سبک استخراج می‌شوند. در گام بعد، فاصله ماهالانویس برای پایش آماری تغییر توزیع ویژگی‌ها نسبت به دامنه مرجع به کار گرفته می‌شود. افزایش معنادار این فاصله به عنوان نشانه‌ای از وقوع یا تشدید رانش در نظر گرفته می‌شود. در نهایت، با اعمال روش انطباق دامنه خصمانه زیرفضایی در فضای ویژگی، اثر رانش از طریق انطباق بدون نظارت با داده‌های دامنه مقصد و بدون نیاز به برچسب‌های جدید و با کمترین بار محاسباتی جبران می‌شود تا پایداری و دقت سیستم در بلندمدت حفظ گردد.

مشارکت‌های اصلی این پژوهش عبارت‌اند از:

۱. ارائه یک شبکه 1D-CNN سبک برای استخراج خودکار ویژگی‌های زمانی از سیگنال‌های حسگرهای گازی MOS.

۲. استفاده از فاصله ماهالانویس برای پایش تغییر توزیع ویژگی‌ها و شناسایی نشانه‌های رانش.

۳. به کارگیری انطباق دامنه خصمانه مبتنی بر زیرفضا برای جبران رانش بدون نیاز به برچسب‌های جدید در دامنه مقصد.

۴. ارزیابی قابلیت استقرار چارچوب پیشنهادی بر سخت‌افزار لبه از نظر تعداد پارامترها، زمان استنتاج و دقت عملکرد.

ساختار مقاله حاضر بدین صورت است که در بخش دوم، مبانی نظری حسگرهای گازی و پدیده رانش بررسی شده است. در بخش سوم، تئوری مدل‌سازی پیشنهادی ارائه می‌گردد. در بخش چهارم، معیارهای ارزیابی معرفی می‌شوند. بخش پنجم به بحث و بررسی نتایج شبیه‌سازی اختصاص یافته و در نهایت، نتیجه‌گیری در بخش ششم ارائه خواهد شد.

۲- مبانی نظری حسگرهای گازی نیم‌رسانا

۲-۱- مکانیزم عملکرد حسگر

حسگرهای گازی مقاومتی مبتنی بر اکسیدهای فلزی نیم‌رسانا (MOS^2) از متداول‌ترین و پرکاربردترین ادوات در سامانه‌های پایش گاز به شمار می‌روند [۳۲، ۳]. اساس عملکرد این حسگرها بر تغییر خواص الکتریکی ماده حساس در اثر برهم‌کنش شیمیایی با مولکول‌های گاز استوار است [۳۳]. در ساده‌ترین بیان، زمانی که یک گاز هدف با سطح ماده نیم‌رسانا تماس پیدا می‌کند، فرآیند جذب سطحی^۳ رخ داده و واکنش‌های اکسایش-کاهش سبب تغییر در تراکم حامل‌های بار (الکترون یا حفره) می‌شود. این تغییر در چگالی حامل‌ها، مستقیماً مقاومت الکتریکی حسگر را دگرگون می‌کند [۳۴، ۷].

بیشتر حسگرهای MOS از مواد نوع n مانند ZnO ، SnO_2 یا WO_3 ساخته می‌شوند [۳۵، ۲۱]. در این مواد، الکترون‌ها، حامل‌های اکثریت هستند. در دمای کاری مشخص (معمولاً بین ۲۰۰ تا ۴۰۰ درجه سانتی‌گراد)، اکسیژن موجود در هوا بر سطح ماده جذب شده و با دریافت الکترون از نوار رسانش، به گونه‌های اکسیژن یونی جذب‌شده، از جمله O^- ، O_2^- و در برخی شرایط

^۱ One-Dimensional Convolutional Neural Network

^۲ Metal-Oxide Semiconductor

^۳ Adsorption

O^2 ، تبدیل می‌شود [۳۶، ۳۷]. نوع و غلبه هر یک از این گونه‌ها به دمای کاری، ماده حساس و ویژگی‌های سطح وابسته است. این فرآیند موجب تشکیل لایه تهی^۱ در نزدیکی سطح و افزایش مقاومت الکتریکی حسگر می‌گردد [۷، ۳۴].

زمانی که گازهای احیاکننده نظیر CO وارد محیط می‌شوند، با یون‌های اکسیژن جذب‌شده واکنش داده و الکترون‌های به‌دام‌افتاده را آزاد می‌کنند [۷، ۳۲]. در نتیجه ضخامت لایه تهی کاهش یافته و رسانایی افزایش می‌یابد. برعکس، در حضور گازهای اکسیدکننده، معمولاً الکترون‌های بیشتری از ماده حساس برداشت می‌شود یا تراکم الکترون‌های آزاد کاهش می‌یابد. در نتیجه، برای نیم‌رساناهای نوع n، ضخامت لایه تهی افزایش یافته و مقاومت الکتریکی حسگر بیشتر می‌شود [۸، ۳۳]. بنابراین، نوع گاز (اکسیدکننده یا احیاکننده) جهت تغییر مقاومت را تعیین می‌کند.

پاسخ حسگر در منابع مختلف با روابط متفاوتی تعریف می‌شود و انتخاب رابطه به نوع ماده، نوع گاز و قرارداد پژوهش وابسته است. در این پژوهش، پاسخ نسبی حسگر مطابق رابطه (۱) تعریف می‌شود:

$$S = \frac{R_g - R_a}{R_a} \quad (1)$$

که در آن، R_a مقاومت حسگر در حضور هوای مرجع و R_g مقاومت حسگر در حضور گاز هدف است.

این رابطه یک معیار بدون بعد برای سنجش حساسیت حسگر فراهم می‌کند و امکان مقایسه عملکرد مواد مختلف را مهیا می‌سازد. در برخی کاربردها، به‌ویژه برای مواد نوع n، در مواجهه با گازهای احیاکننده، از نسبت R_a/R_g نیز استفاده می‌شود تا مقدار پاسخ همواره مثبت باشد [۸، ۳۵].

علاوه بر واکنش‌های شیمیایی سطحی، عوامل فیزیکی متعددی نیز بر عملکرد حسگر اثر گذارند. اندازه دانه‌های نانومتری، تخلخل ساختار، سطح ویژه بالا و حضور نقص‌های بلوری می‌توانند نقش تعیین‌کننده‌ای در افزایش حساسیت داشته باشند [۲، ۳۸]. هنگامی که اندازه دانه به مرتبه طول دبی^۲ نزدیک شود، کل حجم دانه، تحت تأثیر لایه تهی قرار گرفته و تغییرات مقاومت به‌شدت تقویت می‌شود [۷، ۳۲]. این موضوع دلیل استفاده گسترده از نانوساختارها در طراحی حسگرهای مدرن است [۲۱].

همچنین پارامترهایی نظیر دمای کاری، رطوبت نسبی و پایداری حرارتی ماده بر تکرارپذیری پاسخ تأثیر دارند. کنترل دقیق دمای حسگر معمولاً با استفاده از گرم‌کن داخلی انجام می‌شود تا واکنش‌های سطحی، در محدوده بهینه فعال باقی بمانند [۸، ۳۵]. با این حال، همین وابستگی به دما و شرایط محیطی می‌تواند در بلندمدت موجب تغییر تدریجی ویژگی‌های سطحی و بروز پدیده رانش شود که در بخش‌های بعدی به آن پرداخته خواهد شد [۳۹].

۲-۲- مواد مورد استفاده در حسگرهای گازی

انتخاب ماده حساس در حسگرهای گازی نیم‌رسانا، نقش تعیین‌کننده‌ای در حساسیت، انتخاب‌پذیری، دمای کاری و پایداری بلندمدت حسگر دارد [۳۲، ۴۰]. عملکرد این مواد به ویژگی‌هایی مانند ساختار الکترونیکی، مورفولوژی، اندازه دانه، تخلخل، نقص‌های بلوری و شیمی سطح وابسته است. زیرا این عوامل، جذب و واکنش مولکول‌های گاز و در نتیجه تغییر غلظت حامل‌های بار را کنترل می‌کنند [۸، ۳۵]. در میان مواد حساس مختلف، اکسیدهای فلزی نیم‌رسانا به دلیل پایداری مناسب، امکان تولید با ساختارهای متنوع و قابلیت تنظیم خواص سطحی، کاربرد گسترده‌ای در حسگرهای گازی مقاومتی دارند [۴۱، ۴۲].

¹ Depletion Layer

² Debye Length

اکسید قلع (SnO_2)، اکسید روی (ZnO)، اکسید تیتانیوم (TiO_2)، اکسید تنگستن (WO_3) و اکسید ایندیم (In_2O_3) از مهم‌ترین مواد مورد استفاده در این حسگرها هستند. SnO_2 به دلیل پایداری شیمیایی و پاسخ مناسب به گازهای احیاکننده، یکی از پرکاربردترین اکسیدهای فلزی در حسگرهای گازی محسوب می‌شود [۴۳] و ویژگی‌های سطحی و امکان تولید آن در قالب نانو ساختارهای مختلف، ظرفیت برهم کنش آن با گاز هدف را افزایش می‌دهد [۳۲]. ZnO نیز یک نیم‌رسانای نوع n با گاف انرژی پهن است که قابلیت تولید در ریخت‌شناسی‌های متنوعی مانند نانومیل و نانوسیم را دارد [۴۴] و در تشخیص برخی ترکیبات آلی فرار و گازهای سمی به کار می‌رود [۳۵]. پاسخ این ماده را می‌توان با کنترل ساختار، ابعاد و ویژگی‌های سطحی آن تنظیم کرد [۳۵].

در کنار این مواد، TiO_2 به دلیل پایداری شیمیایی و حرارتی و خواص فوتوکاتالیستی مورد توجه قرار گرفته است [۴۵] و نانو ساختارهای آن در برخی کاربردهای حسگری، از جمله تشخیص هیدروژن، استفاده شده‌اند [۴۶]. WO_3 نیز پاسخ و انتخاب‌پذیری مناسبی در برابر گازهای اکسیدکننده، به‌ویژه دی‌اکسید نیتروژن، نشان می‌دهد [۴۷] و از این رو در حسگرهای پایش آلاینده‌های نیتروژنی کاربرد دارد [۴۸]. همچنین، In_2O_3 به دلیل رسانایی مناسب و فعالیت سطحی بالا، برای تشخیص غلظت‌های پایین برخی گازها بررسی شده است [۴۹]. با وجود تفاوت در عملکرد این اکسیدها، سازوکار پاسخ آن‌ها عموماً به برهم کنش اکسیژن و گاز هدف با سطح ماده و تغییر چگالی حامل‌های بار وابسته است [۳۷].

استفاده از نانو ساختارها با افزایش نسبت سطح به حجم و تعداد سایت‌های فعال، می‌تواند حساسیت حسگر را بهبود دهد [۳۸]. با این حال، افزایش فعالیت سطحی ممکن است حساسیت ماده را نسبت به آلودگی سطح، تغییرات محیطی و دگرگونی‌های ساختاری بلندمدت نیز افزایش دهد. این تغییرات از عوامل مؤثر در ناپایداری پاسخ و شکل‌گیری رانش حسگر به شمار می‌روند [۳۹، ۵۰]. بنابراین، هرچند انتخاب و مهندسی ماده حساس برای بهبود عملکرد اولیه ضروری است، حفظ دقت در بهره‌برداری بلندمدت مستلزم استفاده از روش‌های کالیبراسیون و جبران رانش نیز خواهد بود [۳۰]. در پژوهش حاضر، تمرکز بر جبران محاسباتی این تغییرات در خروجی آرایه حسگر است و بررسی تفصیلی ویژگی‌های هر ماده خارج از دامنه پژوهش قرار دارد. بنابراین، انتخاب ماده مناسب تنها یکی از مراحل بهبود عملکرد حسگر است. برای حفظ دقت در بهره‌برداری بلندمدت، می‌توان از راهکارهای کالیبراسیون، کنترل شرایط محیطی و روش‌های جبران رانش مبتنی بر داده استفاده کرد [۲۹، ۳۱]. در پژوهش حاضر، از مدل‌های یادگیری عمیق به‌عنوان یک راهکار محاسباتی برای شناسایی و جبران تغییرات تدریجی خروجی آرایه حسگر استفاده می‌شود [۳۰، ۵۱].

۳- تئوری مدل‌سازی پیشنهادی

۳-۱- فرمولاسیون ریاضی و مدل‌سازی داده‌های آرایه حسگر

در سامانه‌های بویایی الکترونیکی^۱، پاسخ آرایه‌ای متشکل از M حسگر گازی نیم‌رسانای اکسید فلزی (MOS) در مواجهه با نمونه‌های گاز در طول زمان ثبت می‌شود [۱، ۳، ۳۳]. برای هر آزمایش k، پاسخ زمانی حسگرها به‌صورت یک ماتریس دو بعدی نمایش داده می‌شود [۵۲]:

$$X_k \in R^{M \times T} \quad (2)$$

که در آن T تعداد نقاط نمونه‌برداری زمانی در طول دوره پاسخ (شامل فازهای تزریق گاز و پاک‌سازی) است. با فرض وجود پدیده رانش، توزیع احتمالی داده‌های ورودی در طول زمان دستخوش تغییر می‌شود [۲۰، ۳۹].

¹ E-nose

به بیان ریاضی، اگر $P(X)$ توزیع احتمالاتی داده‌های حسگر در زمان کالیبراسیون اولیه (دامنه مبدأ D_S) و $P'(X)$ توزیع داده‌ها در زمان‌های بعدی (دامنه مقصد D_T) باشد، پدیده رانش زمانی رخ می‌دهد که $P(X) \neq P'(X)$ باشد [۲۰]. هدف این مدل‌سازی، استخراج ویژگی‌های غیروابسته به زمان برای غلبه بر این ناهمخوانی توزیع است.

۲-۳- مجموعه داده و نحوه آماده‌سازی داده‌ها

در این پژوهش، ارزیابی مدل پیشنهادی بر روی مجموعه داده‌ی استاندارد و مرجع [۴] صورت گرفته است. این داده‌ها شامل ثبت طولانی مدت پاسخ آرایه‌ای متشکل از ۱۶ حسگر شیمیایی نیمه‌هادی اکسید فلزی (MOS) در برابر ۶ گاز مختلف (آمونیاک، استالدهید، استون، اتیلن، اتانول و تولوئن) در غلظت‌های مختلف طی یک بازه زمانی ۳۶ ماهه است [۴]. از مجموع ۱۳۹۱۰ اندازه‌گیری موجود، پس از اعمال پیش‌پردازش، فیلتر نویز و حذف رکوردهای با داده‌های مفقود، تعداد ۱۲۶۵۰ نمونه اندازه‌گیری ساختاریافته برای آموزش و ارزیابی مدل نهایی انتخاب شد.

برای شبیه‌سازی دقیق پدیده‌ی رانش زمانی حسگرها، داده‌ها بر اساس توزیع زمانی ثبت شده به دسته‌های مجزا تقسیم شدند. دسته‌های ۱ تا ۵ (شامل ۷۲۱۰ نمونه مربوط به ماه‌های اولیه اندازه‌گیری) به عنوان دامنه مبدأ (D_S) برای آموزش اولیه مدل طبقه‌بند و استخراج ویژگی تخصیص یافتند. دسته‌های ۶ و ۷ (شامل ۲۲۴۰ نمونه) به عنوان داده‌های اعتبارسنجی برای تنظیم ابرپارامترها و تعیین آستانه پذیرش فاصله ماهالانویس استفاده شدند. در نهایت، دسته‌های ۸ تا ۱۰ (شامل ۳۲۰۰ نمونه مربوط به دوره‌های انتهای پروژه که بیشترین رانش را تجربه کرده‌اند) به عنوان دامنه مقصد آزمون (D_T) جهت ارزیابی نهایی کارایی مدل جبران‌سازی در نظر گرفته شدند. در تمامی مراحل، برچسب کلاس‌های گاز در دامنه مقصد در فرآیند انطباق خصمانه زیرفضایی بدون نظارت دخالت داده نشده و صرفاً در فاز نهایی ارزیابی دقت خروجی مورد استفاده قرار گرفته است.

۳-۳- راهبرد تقسیم داده‌ها و جلوگیری از نشت اطلاعات

یکی از چالش‌های اساسی در ارزیابی سیستم‌های جبران رانش، جلوگیری از نشت اطلاعات بین دامنه‌های زمانی است. در این پژوهش، از تقسیم تصادفی نمونه‌های کل بازه زمانی خودداری شد. زیرا توزیع تصادفی نمونه‌ها میان داده‌های آموزش و آزمون منجر به بیش‌برآورد غیرواقعی کارایی مدل در مواجهه با رانش تدریجی می‌شود [۳۱]. تقسیم‌بندی داده‌ها صرفاً بر مبنای توالی زمانی رخدادها صورت پذیرفته است. پارامترهای پیش‌پردازش، میانگین‌های ویژگی و ماتریس کوواریانس لازم برای محاسبه مجذور فاصله ماهالانویس (D_M^2) تنها از روی داده‌های آموزش دامنه مبدأ استخراج شدند و داده‌های آزمون در هیچ یک از مراحل آموزش، انتخاب ابرپارامترها و یادگیری فیلترهای جبران‌ساز استفاده نشدند.

به دلیل ماهیت تصادفی فرآیند بهینه‌سازی و مقداردهی اولیه وزن‌های شبکه 1D-CNN سبک، تمام مراحل آموزش و ارزیابی در ۱۰ اجرای کاملاً مستقل با بذره‌های تصادفی متفاوت تکرار گردید تا رفتار آماری مدل و پایداری آن تایید شود.

۴-۳- پیش‌پردازش و پایدارسازی خط مبنا

برای حذف نوسانات فرکانس بالا (نویزهای حرارتی و الکتریکی) و خنثی‌سازی اثرات رانش خط مبنای اولیه، از روش نرمال‌سازی تفاضلی نسبی استفاده می‌شود. برای هر پاسخ زمانی $x_i(t)$ از حسگر i ام در زمان t ، سیگنال پیش‌پردازش شده $\tilde{x}_i(t)$ به صورت رابطه (۳) تعریف می‌شود [۱۱]:

$$\tilde{x}_i(t) = \frac{x_i(t) - b_i}{b_i + \epsilon} \quad (3)$$

که در آن b_i میانگین مقاومت حسگر در فاز پاک‌سازی اولیه (هوای مرجع پیش از تزریق گاز) و ϵ یک مقدار ثابت بسیار کوچک (مانند 10^{-5}) جهت پایدارسازی عددی و جلوگیری از تقسیم بر صفر است. این تبدیل مقیاس، تغییرات نسبی پاسخ را برجسته کرده و ناپایداری‌های فیزیکی ناشی از تغییرات دمای محیط را تا حد زیادی خنثی می‌سازد [۳۴، ۵۰].

۵-۳- استخراج ویژگی زمانی با مدل 1D-CNN سبک

برای استخراج خودکار ویژگی‌های زمانی، بدون آن که نیازی به طراحی دستی ویژگی‌ها باشد، یک شبکه عصبی پیچشی یک‌بعدی سبک (1D-CNN) طراحی شده است [۳۰، ۵۱]. برای کاهش پیچیدگی محاسباتی و امکان پیاده‌سازی روی سخت‌افزارهای لبه، لایه‌های پیچش استاندارد با لایه‌های پیچش تفکیک‌پذیر عمقی جایگزین شده‌اند [۱۴، ۱۵].

نگاشت غیرخطی شبکه عصبی را می‌توان به صورت (۴) فرمولاسیون کرد:

$$h_k = G_\theta(X_k) \quad (۴)$$

که در آن $h_k \in R^d$ بردار ویژگی خروجی با بعد d و θ نمایانگر پارامترهای وزن و بایاس بهینه‌سازی شده شبکه است. فرآیند محاسبات در لایه پیچش تفکیک‌پذیر عمقی شامل دو مرحله پیچش عمقی و پیچش نقطه‌ای است که نسبت به لایه‌های معمولی، پارامترهای مدل را به میزان (۵) کاهش می‌دهد [۱۵، ۱۶]:

$$Reduction Factor = \frac{1}{N} + \frac{1}{D_k^2} \quad (۵)$$


که در آن D_k اندازه فیلتر و N تعداد کانال‌های خروجی است. این ساختار امکان استخراج بردارهای ویژگی مقاوم را با حداقل توان پردازشی روی پلتفرم‌های لبه فراهم می‌کند [۱۶، ۱۹].

برای پیاده‌سازی مدل 1D-CNN سبک پیشنهادی، ساختاری متشکل از لایه‌های پیچش تفکیک‌پذیر عمقی طراحی شده است تا بار محاسباتی روی پردازنده‌های لبه به حداقل برسد. ورودی مدل، سیگنال پیش‌پردازش شده آرایه حسگر با ابعاد $M \times T$ است. جزئیات ساختار لایه‌ها، ابعاد فیلترها و هاپرپارامترهای آموزش شبکه در جدول ۲ خلاصه شده است.


معماری کلی چارچوب پیشنهادی در شکل ۱ نشان داده شده است. همان‌گونه که در شکل ۱-الف مشاهده می‌شود، ورودی شبکه از پاسخ زمانی M حسگر تشکیل شده و به صورت ماتریس $X_k \in R^{M \times T}$ به مدل اعمال می‌شود. پس از نرمال‌سازی تفاضلی نسبی مطابق رابطه (۳)، یک لایه پیچش عمقی یک‌بعدی با اندازه هسته ۵، الگوهای زمانی هر کانال حسگر را به صورت مستقل استخراج می‌کند. سپس یک پیچش نقطه‌ای با هسته ۱ و ۳۲ فیلتر، اطلاعات کانال‌های مختلف حسگر را با یکدیگر ترکیب می‌نماید. خروجی این مرحله با استفاده از میانگین‌گیری سراسری یک‌بعدی به یک بردار با طول ثابت تبدیل شده و پس از عبور از لایه تمام‌متصل ۶۴ بعدی، بردار ویژگی $h_k \in R^{64}$ تولید می‌شود. استفاده از پیچش تفکیک‌پذیر عمقی موجب کاهش تعداد پارامترها و عملیات محاسباتی در مقایسه با پیچش استاندارد می‌شود [۱۴، ۱۶، ۱۸].

جدول ۲ - مشخصات معماری و هایپرپارامترهای آموزش مدل 1D-CNN سبک

پارامتر / لایه	مشخصات تفصیلی پیاده‌سازی	مرجع / توضیح
لایه ورودی	ماتریس سیگنال پیش‌پردازش شده با ابعاد $M \times T$	رابطه (۳)
لایه پیش‌پرداز اول	تعداد فیلتر: M ، اندازه هسته (Kernel): 1×5 ، گام حرکت: ۱	استخراج ویژگی‌های زمانی انفرادی [۱۴]
لایه پیش‌پرداز دوم	تعداد فیلتر: ۳۲، اندازه هسته: 1×1 ، تابع فعال‌سازی: ReLU	ترکیب ویژگی‌های کانال‌های مختلف [۱۵]
لایه پولینگ	لایه میانگین‌گیری جهانی یک‌بعدی ۱	کاهش بعد و جلوگیری از بیش‌برازش [۱۶]
لایه تمام‌متصل	بعد خروجی: (d) ۶۴، تابع فعال‌سازی: ReLU	تولید بردار ویژگی نهایی h_k
لایه خروجی طبقه‌بندی	لایه تمام‌متصل با ۶ خروجی و تابع Softmax	پیش‌بینی احتمال تعلق نمونه به هر یک از شش کلاس گاز
خروجی استخراج‌کننده ویژگی	برداری $h_k \in R^{64}$ پیش از لایه Softmax	ورودی ماژول‌های تشخیص و جبران رانش
تابع هزینه	خطای انتروپی متقاطع چند کلاسه ۲	متناسب با توزیع کلاس‌های گاز [۳۰]
بهینه‌ساز	الگوریتم آدام با نرخ یادگیری اولیه 10^{-3} و کاهش تدریجی	پایداری همگرایی در یادگیری سبک [۳۰]
تعداد دوره‌ها	۱۰۰ دوره (با شرط توقف زود هنگام در صورت عدم بهبود در ۱۰ دوره متوالی)	پیشگیری از بیش‌برازش روی داده‌های رانش یافته
اندازه دسته	۳۲ نمونه	متناسب با محدودیت حافظه سیستم‌های لبه [۱۷]



(الف)



(ب)

شکل ۱ - معماری چارچوب پیشنهادی برای تشخیص و جبران رانش حسگرهای گازی MOS: (الف) ساختار شبکه 1D-CNN سبک برای استخراج خودکار ویژگی‌های زمانی، (ب) جریان تشخیص رانش با فاصله ماحالانویس و جبران بدون نظارت در فضای ویژگی.

¹ Global Average Pooling 1D

² Categorical Cross-Entropy

مطابق شکل ۱-ب، آموزش اولیه استخراج‌کننده ویژگی و طبقه‌بند شش کلاسه با استفاده از نمونه‌های برچسب‌دار دامنه مبدأ و تابع هزینه انتروپی متقاطع انجام می‌شود. پس از پایان آموزش، میانگین μ و ماتریس کوواریانس Σ ویژگی‌های دامنه مبدأ محاسبه و به عنوان مشخصات فضای مرجع ذخیره می‌شوند. در زمان بهره‌برداری، ویژگی نمونه‌های جدید به وسیله شبکه 1D-CNN سبک استخراج و فاصله ماکسیمالیسی آن‌ها نسبت به توزیع مرجع محاسبه می‌شود. در صورت عبور $D_M^2(h)$ از آستانه λ ، ماژول جبران رانش فعال شده و نگاشت f_ϕ ویژگی‌های دامنه مقصد را بدون استفاده از برچسب‌های دامنه مقصد و از طریق کمینه‌سازی اختلاف توزیعی با دامنه مبدأ اصلاح می‌کند [۲۳]. در نهایت، ویژگی‌های جبران‌شده u_k به طبقه‌بند آموزش‌دیده روی دامنه مبدأ اعمال می‌شوند. بنابراین، نیازی به آموزش مجدد طبقه‌بند با داده‌های برچسب‌دار دامنه مقصد وجود ندارد.

آموزش مدل ابتدا روی داده‌های کالیبراسیون اولیه (دامنه مبدأ) انجام می‌شود تا بردارهای ویژگی پایه استخراج گردند. سپس، بردارهای خروجی لایه تمام‌متصل h_k به عنوان ورودی ماژول تشخیص رانش (بخش ۳-۶) و ماژول جبران تطبیقی (بخش ۳-۷) مورد استفاده قرار می‌گیرند.

۳-۶- تشخیص آماری رانش مبتنی بر فاصله ماکسیمالیسی

پدیده رانش حسگر منجر به انحراف بردارهای ویژگی استخراج‌شده از فضای کالیبراسیون اولیه می‌شود. جهت پایش وضعیت آنالین و تشخیص زمان دقیق وقوع رانش، از معیار فاصله ماکسیمالیسی (D_M) بر روی ویژگی‌های استخراج‌شده بهره گرفته می‌شود [۳۱، ۵۳]. اگر $\mu \in R^d$ ، میانگین بردارهای ویژگی در فاز کالیبراسیون و $\Sigma \in R^{d \times d}$ ماتریس کوواریانس متناظر باشد، فاصله ماکسیمالیسی برای یک نمونه ویژگی جدید h به صورت رابطه (۶) محاسبه می‌شود [۵۳]:

$$D_M^2(h) = (h - \mu)^T \Sigma^{-1} (h - \mu) \quad (6)$$

که در آن h بردار ویژگی استخراج‌شده از شبکه 1D-CNN سبک و μ و Σ به ترتیب میانگین و ماتریس کوواریانس ویژگی‌های دامنه مبدأ هستند. توزیع این شاخص به صورت (۷) تعریف می‌شود:

$$D_M^2(h) \sim \chi_d^2 \quad (7)$$

برخلاف فاصله اقلیدسی، این معیار همبستگی بین ویژگی‌های مختلف آرایه حسگر را در نظر می‌گیرد. با فرض توزیع نرمال چندمتغیره برای داده‌های بدون رانش، متغیر D_M^2 از توزیع مجذور کای (χ^2) با d درجه آزادی پیروی می‌کند [۵۴]. آستانه تشخیص رانش (λ) با استفاده از سطح معنی‌داری z تعیین می‌شود (۸):

$$z = \begin{cases} 1, & \text{if } D_M^2(h) > \lambda \\ 0 & \text{otherwise} \end{cases} \quad (8)$$

که در آن $\lambda = \chi_{1-\alpha, d}^2$ است. عبور از این آستانه، فرمان فعال‌سازی ماژول جبران‌سازی رانش را صادر می‌کند [۲۱].

۳-۷- جبران تطبیقی رانش در فضای ویژگی^۱

پس از شناسایی رانش، لازم است اثر تغییرات زمانی و محیطی بر نمایش ویژگی‌ها کاهش یابد. زیرا توزیع ویژگی‌های استخراج‌شده از داده‌های مقصد ممکن است با توزیع داده‌های مبدأ تفاوت داشته باشد. در این پژوهش، این مسئله به صورت انطباق دامنه خصمانه زیرفضایی مدل می‌شود [۲۵، ۴۳]. در این چارچوب، شبکه استخراج‌کننده، ویژگی‌ها را به یک زیرفضای مشترک نگاشت می‌کند. به گونه‌ای که ویژگی‌های مربوط به کلاس‌های یکسان، قابلیت تفکیک خود را حفظ کنند و در عین حال، تشخیص

¹ Feature Domain Compensation

دامنه مبدأ و مقصد از روی آن‌ها دشوار شود [۲۴، ۲۸]. این ایده با چارچوب‌های یادگیری خصمانه دامنه، به‌ویژه شبکه‌های خصمانه دامنه‌گرا، هم‌راستا است.

فرض کنید $\mathbf{h}_k = \mathbf{E}_\theta(\mathbf{x}_k)$ نمایش ویژگی نمونه $\mathbf{x}_k$ باشد که توسط استخراج‌کننده ویژگی $\mathbf{E}_\theta$ تولید شده است. ویژگی تطبیق‌یافته در زیرفضای مشترک از رابطه (۹) به‌دست می‌آید [۲۴، ۲۶]:

$$u_k = f_\phi(h_k) = P_\phi h_k - \delta_\phi(h_k) \quad (9)$$

که در آن، P_ϕ ماتریس نگاشت به زیرفضای مشترک، $\delta_\phi(h_k)$ مؤلفه اصلاحی تخمین‌زده‌شده برای کاهش اثر رانش، و f_ϕ نگاشت تطبیقی ویژگی است. برخلاف کم کردن یک بردار ثابت از ویژگی‌ها، استفاده از تابع $\delta_\phi(0)$ امکان مدل‌سازی اصلاحی وابسته به نمونه را فراهم می‌کند. در نتیجه، نگاشت تطبیقی می‌تواند تغییرات غیرخطی و وابسته به وضعیت کاری حسگر را بهتر نمایش دهد.

برای نزدیک کردن توزیع ویژگی‌های دو دامنه، یک متمایزکننده دامنه D_ω به‌صورت خصمانه آموزش داده می‌شود [۲۴، ۲۵]. این متمایزکننده تلاش می‌کند با استفاده از ویژگی $\mathbf{u}$ ، دامنه نمونه را تشخیص دهد. در حالی که استخراج‌کننده و نگاشت تطبیقی تلاش می‌کنند اطلاعات دامنه‌ای را از ویژگی‌های مشترک حذف کنند. تابع زیان خصمانه دامنه به‌صورت رابطه (۱۰) تعریف می‌شود [۲۴، ۲۸]:

$$L_{adv}(\theta, \phi, \omega) = -\frac{1}{n_s} \sum_{i=1}^{n_s} \log D_\omega(u_i^s) - \frac{1}{n_t} \sum_{j=1}^{n_t} \log[1 - D_\omega(u_j^t)] \quad (10)$$

که در آن، $\mathbf{u}_i^s = f_\phi(\mathbf{E}_\theta(\mathbf{x}_i^s))$ و $\mathbf{u}_j^t = f_\phi(\mathbf{E}_\theta(\mathbf{x}_j^t))$ به ترتیب ویژگی‌های تطبیق‌یافته دامنه مبدأ و مقصد هستند. در این رابطه، $D_\omega(\mathbf{u})$ احتمال تعلق ویژگی $\mathbf{u}$ به دامنه مبدأ را نشان می‌دهد. پارامترهای متمایزکننده با کمینه‌سازی L_{adv} آموزش داده می‌شوند. اما استخراج‌کننده و نگاشت تطبیقی در جهت پیشینه‌سازی این زیان بهینه می‌شوند تا متمایزکننده نتواند دامنه نمونه را به‌درستی تشخیص دهد. بنابراین، مسئله بهینه‌سازی کلی را می‌توان به‌صورت (۱۱) نوشت [۲۴، ۲۸]:

$$\min_{\theta, \phi} \max_{\omega} L_{cls}(\theta, \phi) - \lambda_{adv} L_{adv}(\theta, \phi, \omega) \quad (11)$$

که در آن، L_{cls} زیان طبقه‌بندی داده‌های برچسب‌دار مبدأ و λ_{adv} ضریب کنترل‌کننده سهم انطباق خصمانه است. در پیاده‌سازی عملی، این بازی کمینه-بیشینه را می‌توان با لایه معکوس‌گر گرادیان یا روش‌های بهینه‌سازی معادل پیاده‌سازی کرد [۲۴، ۲۸]. برای پایدارسازی آموزش و کاهش فاصله آماری بین دو دامنه، می‌توان یک جمله منظم‌ساز مبتنی بر ناهمسانی میانگین بیشینه^۱ نیز مطابق (۱۲) به تابع هدف افزود [۲۳، ۲۷]:

$$L_{MMD}(D_s, D_t) = \left\| \frac{1}{n_s} \sum_{i=1}^{n_s} \varphi(u_i^s) - \frac{1}{n_t} \sum_{j=1}^{n_t} \varphi(u_j^t) \right\|_H^2 \quad (12)$$

که در آن، $\varphi(0)$ نگاشت ویژگی به فضای هیلبرت بازتولیدکننده هسته H است. به‌صورت معادل، این کمیت را می‌توان با استفاده از تابع هسته $k(0, 0)$ مطابق (۱۳) محاسبه کرد [۲۳، ۲۷]:

$$L_{MMD} = \frac{1}{n_s^2} \sum_{i=1}^{n_s} \sum_{i'=1}^{n_s} k(u_i^s, u_{i'}^s) + \frac{1}{n_t^2} \sum_{j=1}^{n_t} \sum_{j'=1}^{n_t} k(u_j^t, u_{j'}^t) - \frac{2}{n_s n_t} \sum_{i=1}^{n_s} \sum_{j=1}^{n_t} k(u_i^s, u_j^t) \quad (13)$$

¹ Maximum Mean Discrepancy (MMD)

در این پژوهش، تابع هدف نهایی مطابق (۱۴) به صورت ترکیبی از زیان طبقه‌بندی، زیان خصمانه دامنه و جمله MMD در نظر گرفته می‌شود [۲۴، ۲۶]:

$$L_{total} = L_{cls} + \lambda_{MMD} \cdot L_{MMD} + \lambda_{adv} \cdot L_{adv}^* \quad (14)$$

که در آن، λ_{MMD} و λ_{adv} ضرایب تنظیم هستند و L_{adv}^* با توجه به علامت مورد استفاده در پیاده‌سازی کمینه-بیشینه تعریف می‌شود. جمله خصمانه، هم‌ترازی دامنه را از طریق غیرقابل تشخیص کردن دامنه ویژگی‌ها دنبال می‌کند، در حالی که جمله MMD اختلاف میانگین‌های نگاشت‌یافته دو توزیع را کاهش می‌دهد. ترکیب این دو سازوکار می‌تواند از اتکای مدل به نشانه‌های اختصاصی دامنه جلوگیری کند و پایداری نمایش ویژگی را در برابر رانش زمانی افزایش دهد [۲۴، ۲۶].

در صورت در دسترس بودن نمونه‌های مقصد بدون برچسب، آموزش انطباق می‌تواند بدون تخصیص برچسب به داده‌های مقصد انجام شود. پس از آموزش، تنها نگاشت f_{ϕ} و استخراج‌کننده ویژگی برای تبدیل نمونه‌های جدید به زیرفضای تطبیق‌یافته به کار گرفته می‌شوند و طبقه‌بند آموزش‌دیده روی داده‌های مبدأ می‌تواند بدون بازآموزی کامل مورد استفاده قرار گیرد. با این حال، حفظ دقت طبقه‌بندی به این شرط وابسته است که فرض هم‌تغییری یا ثبات معنایی بین دامنه‌ها برقرار باشد. یعنی رابطه میان کلاس گاز و ساختار ویژگی‌ها در دامنه مبدأ و مقصد به طور اساسی تغییر نکرده باشد. بنابراین، انطباق خصمانه نباید صرفاً به حذف اطلاعات دامنه‌ای منجر شود، بلکه باید هم‌زمان قابلیت تفکیک کلاس‌های گاز را نیز حفظ کند. این ملاحظه در روش‌های انطباق زیرفضایی و انطباق زیردامنه‌ای نیز مورد تأکید قرار گرفته است [۲۶، ۲۷].

۴- معیارهای ارزیابی

برای سنجش دقیق کارایی چارچوب پیشنهادی، در تشخیص و جبران رانش و همچنین ارزیابی قابلیت اجرای آن در محیط‌های لبه، معیارهای ارزیابی در سه بخش عملکرد طبقه‌بندی گاز، کارایی جبران‌سازی رانش و پیچیدگی سخت‌افزاری لبه دسته‌بندی می‌شوند.

۴-۱- معیارهای عملکرد طبقه‌بندی گاز

دقت کلی مدل در تفکیک انواع گازها و تخمین غلظت آن‌ها با معیارهای استاندارد ماتریس اغتشاش سنجیده می‌شود [۵۵، ۵۶]:

- دقت کلی^۱

$$\text{Accuracy} = \frac{TP + TN}{TP + TN + FP + FN} \quad (15)$$

- امتیاز F1^۲:

$$\text{F1 - Score} = \frac{2 \times \text{Precision} \times \text{Recall}}{\text{Precision} + \text{Recall}} \quad (16)$$

که در آن‌ها TP ، TN ، FP و FN به ترتیب نشان‌دهنده مثبت واقعی، منفی واقعی، مثبت کاذب و منفی کاذب هستند [۵۵، ۵۶].

۴-۲- معیارهای سنجش کارایی جبران‌سازی رانش

برای ارزیابی میزان موفقیت الگوریتم در کاهش اثرات رانش از شاخص‌های زیر استفاده می‌شود [۲۱، ۳۰، ۳۹، ۵۰]:

- بهبود دقت پس از جبران (ΔAcc):

¹ Accuracy

² F1-Score

$$\Delta Acc = Acc_{comp} - Acc_{uncomp} \quad (17)$$

در این رابطه، Acc_{comp} دقت طبقه‌بندی روی داده‌های رانش یافته پس از اعمال روش جبران‌سازی و Acc_{uncomp} دقت مدل روی همان داده‌ها بدون جبران‌سازی است. مقدار ΔAcc مثبت بیانگر بهبود عملکرد طبقه‌بندی پس از جبران رانش است [۵۵، ۵۶].

- فاصله توزیع با معیار واگرایی کولبک-لایبلا^۱ [۵۷]:

$$D_{KL}(P_{ref} || P_{comp}) = \sum_{x \in \mathcal{X}} P_{ref}(x) \log\left(\frac{P_{ref}(x)}{P_{comp}(x)}\right) \quad (18)$$

این معیار میزان شباهت توزیع ویژگی‌های جبران‌شده (P_{comp}) با توزیع کالیبراسیون مرجع (P_{ref}) را اندازه‌گیری می‌کند. این معیار میزان اختلاف میان توزیع ویژگی‌های جبران‌شده (P_{comp}) و توزیع ویژگی‌های مرجع کالیبراسیون (P_{ref}) را اندازه‌گیری می‌کند. مقدار کمتر واگرایی کولبک-لایبلا نشان می‌دهد که توزیع ویژگی‌های جبران‌شده به توزیع مرجع نزدیک‌تر شده است. با این حال، این شاخص به تنهایی برای اثبات موفقیت جبران‌سازی کافی نیست و باید همراه با معیارهای عملکرد طبقه‌بندی، مانند دقت کلی و امتیاز F1، تفسیر شود.

مقادیر نزدیک به صفر نشان‌دهنده جبران‌سازی کامل اثر رانش است [۵۷].

۳-۴- معیارهای ارزیابی پیچیدگی سخت‌افزاری لبه

برای اثبات سبک بودن و قابلیت اجرای مدل روی سخت‌افزارهای کم‌مصرف، معیارهای محاسباتی زیر اندازه‌گیری می‌شوند [۱۹-۱۷].

- تعداد کل پارامترهای مدل: تعداد وزن‌ها و بایاس‌های قابل آموزش شبکه عصبی است و شاخصی اولیه برای برآورد اندازه مدل به‌شمار می‌رود.
- تعداد عملیات ممیز شناور^۲: شاخصی برای ارزیابی پیچیدگی محاسباتی و توان پردازشی مورد نیاز میکروکنترلر.
- زمان پاسخ‌دهی: میانگین زمان پردازش یک نمونه ورودی بر روی برد سخت‌افزاری لبه (بر حسب میلی‌ثانیه).

۵- بحث و بررسی نتایج شبیه‌سازی

تمامی نتایج ارائه شده در این بخش، میانگین حاصل از ۱۰ اجرای مستقل به همراه انحراف معیار آن‌ها ($Mean \pm Std$) روی مجموعه داده‌ی آزمون زمانی (دسته‌های ۸ تا ۱۰ مجموعه داده) است. معیارهای ثابت ساختاری، مانند تعداد پارامترهای مدل بدون تغییر در بذرها گزارش شده‌اند (جدول ۳). در جدول ۳، علاوه بر مشخصات مجموعه داده و نحوه تقسیم نمونه‌ها، نوع رانش و پلتفرم اجرای آزمایش‌ها نیز گزارش شده است. با توجه به ثبت داده‌ها در بازه‌ای حدود ۳۶ ماه [۴] و سازمان‌دهی آن‌ها در دسته‌های زمانی متوالی، مسئله حاضر به عنوان رانش زمانی بلندمدت بررسی شد. در این چارچوب، فرض اصلی آن است که توزیع ویژگی‌های ورودی بین دامنه مبدأ و دامنه مقصد تغییر می‌کند، یعنی $P_s(X) \neq P_t(X)$ ، درحالی که هدف طبقه‌بندی، یعنی تشخیص نوع گاز، ثابت باقی می‌ماند [۲۰، ۲۱، ۳۱، ۳۹]. باین حال، از آنجا که نرخ و شکل تغییرات در طول زمان الزاماً یکنواخت نیست، در این پژوهش از عبارت «رانش زمانی بلندمدت» به جای «رانش کاملاً تدریجی و یکنواخت» استفاده می‌شود [۳۹، ۵۰]. برای جلوگیری از نشت اطلاعات، تمامی عملیات وابسته به داده، شامل استانداردسازی، استخراج مؤلفه‌های PCA، محاسبه میانگین

¹ Kullback-Leibler Divergence

² FLOPs

و کوواریانس فضای ویژگی، تعیین آستانه تشخیص رانش و تنظیم پارامترهای روش‌های جبران، فقط با استفاده از داده‌های آموزش و در صورت نیاز داده‌های اعتبارسنجی انجام شد. داده‌های دسته‌های ۸ تا ۱۰ تا پایان فرایند انتخاب مدل و تنظیم پارامترها کاملاً دست‌نخورده باقی ماندند [۳۱، ۳۲، ۵۰].

جدول ۳ - مشخصات مجموعه داده و پروتکل ارزیابی در آزمایش‌ها

مشخصه آزمایشی	مقدار / ساختار
نام مجموعه داده مرجع	Chemical Gas Sensor Array Dataset [4]
تعداد کل کانال‌های ورودی (حسگرها)	۱۶ حسگر شیمیایی MOS
تعداد کلاس‌های گاز هدف	۶ کلاس (آمونیاک، استالدهید، استون، اتیلن، اتانول، تولوئن)
نوع رانش مورد بررسی	رانش بلندمدت زمانی و تدریجی در پاسخ آرایه حسگر، ناشی از تغییر توزیع داده‌ها در گذر زمان
ماهیت مدل‌سازی رانش	جابه‌جایی توزیعی بین دامنه مبدأ و دامنه مقصد، به صورت $P(X) \neq P'(X)$ [۴۰، ۴۱]
تعداد کل نمونه‌های نهایی	۱۲۶۵۰ نمونه
نمونه‌های دامنه مبدأ (آموزش - دسته‌های ۱ تا ۵)	۷۲۱۰ نمونه
نمونه‌های اعتبارسنجی (دسته‌های ۶ و ۷)	۲۲۴۰ نمونه
نمونه‌های دامنه مقصد آزمون (دسته‌های ۸ تا ۱۰)	۳۲۰۰ نمونه
راهبرد تقسیم داده‌ها	تقسیم زمانی بر اساس دسته‌های متوالی، بدون اختلاط تصادفی نمونه‌های آموزش و آزمون
تعداد تکرار مستقل آزمایش‌ها	۱۰ بار با بذره‌های تصادفی یکتا
سطح معنی‌داری حد آستانه کای‌دو (α)	۰/۰۵

از نظر پلتفرم اجرا، ارزیابی اصلی در محیط محاسباتی نرم‌افزاری انجام شد و قابلیت استقرار روی سامانه‌های لبه بر اساس شاخص‌های محاسباتی، شامل تعداد پارامترهای فعال، تعداد عملیات ممیز شناور و زمان پاسخ هر نمونه سنجیده شد. این شاخص‌ها در ادبیات پیاده‌سازی مدل‌های یادگیری عمیق سبک، معیارهای رایج برای ارزیابی امکان اجرای مدل روی سخت‌افزارهای محدود و کم‌مصرف محسوب می‌شوند [۱۶-۱۹].

برای ارزیابی کارایی چارچوب پیشنهادی، عملکرد سامانه در سه محور اصلی بررسی می‌شود: دقت طبقه‌بندی، کارایی جبران رانش و پیچیدگی محاسباتی در بستر لبه. مسئله رانش در حسگرهای گازی از مهم‌ترین عوامل کاهش قابلیت اطمینان سامانه‌های بویایی الکترونیکی در کاربردهای بلندمدت است. زیرا در طول زمان، پاسخ حسگرها به علت فرسودگی، تغییرات سطح فعال، نوسانات دما و رطوبت و شرایط محیطی دچار جابه‌جایی توزیعی می‌شود [۱۲، ۲۱، ۳۴]. به همین دلیل، روش‌هایی که صرفاً بر مدل‌سازی ایستای داده‌ها تکیه دارند، معمولاً در سناریوهای واقعی و بلندمدت دچار افت عملکرد می‌شوند [۱۳، ۳۱].


در سال‌های اخیر، استفاده از یادگیری عمیق و روش‌های انطباق دامنه برای مقابله با این چالش مورد توجه قرار گرفته است، زیرا این روش‌ها قادرند بازنمایی‌هایی مقاوم‌تر نسبت به تغییرات غیرخطی و تدریجی داده‌ها استخراج کنند [۲۳، ۲۴، ۲۶، ۳۵]. در این مقاله، انتظار می‌رود ترکیب یک شبکه سبک 1D-CNN با سازوکار تشخیص و جبران رانش، نه تنها دقت طبقه‌بندی را حفظ کند، بلکه، از نظر پیچیدگی محاسباتی نیز برای پیاده‌سازی روی سخت‌افزارهای لبه مناسب باشد [۱۶-۱۸].

۱-۵- تحلیل همگرایی و پایداری آموزش مدل 1D-CNN سبک

پیش از ارزیابی نهایی عملکرد طبقه‌بندی و جبران رانش، روند آموزش مدل 1D-CNN سبک بر روی داده‌های دامنه مبدأ بررسی شد. در این مرحله، مدل با استفاده از نمونه‌های برچسب‌دار دسته‌های ۱ تا ۵ آموزش یافت و داده‌های دسته‌های ۶ و ۷ صرفاً برای اعتبارسنجی، تنظیم ابرپارامترها و انتخاب دوره بهینه آموزش به کار رفتند [۴، ۳۱، ۳۹]. تابع هزینه مورد استفاده، خطای اتروپی

مقاطع چند کلاسه بود و بهینه‌سازی پارامترهای شبکه با الگوریتم بهینه‌سازی آدام^۱ و نرخ یادگیری اولیه 10^{-3} انجام شد. مطابق پروتکل معرفی شده در جدول ۲، حداکثر تعداد دوره‌های آموزشی ۱۰۰ در نظر گرفته شد و در صورت عدم بهبود عملکرد اعتبارسنجی در ۱۰ دوره متوالی، آموزش با سازوکار توقف زودهنگام خاتمه یافت.

برای ارزیابی پایداری فرآیند بهینه‌سازی، نسبت به مقیاردی اولیه وزن‌ها و تصادفی‌بودن آموزش، روند تابع هزینه در ۱۰ اجرای مستقل با بذره‌های تصادفی متفاوت ثبت شد. شکل ۲، میانگین تابع هزینه آموزش و اعتبارسنجی را در هر دوره نشان می‌دهد و نواحی سایه‌دار، یک انحراف معیار حول میانگین نتایج اجراهای مستقل را نمایش می‌دهند. کاهش تدریجی تابع هزینه آموزش بیانگر یادگیری الگوهای زمانی پاسخ حسگرها در دامنه مبدأ است. همچنین کاهش loss آموزش و کاهش یا تثبیت loss اعتبارسنجی نشان می‌دهد که مدل در داده‌های مبدأ فرایند یادگیری را دنبال کرده است. باین‌حال، ارزیابی پایداری آموزش صرفاً بر اساس روند loss کافی نیست. از این رو، میانگین، انحراف معیار و دامنه تغییرات عملکرد اعتبارسنجی در ۱۰ اجرای مستقل نیز گزارش شد. محدودبودن پراکندگی این شاخص‌ها نشان‌دهنده حساسیت نسبتاً کم مدل به مقیاردی اولیه و تصادفی‌بودن فرایند آموزش است [۱۶، ۱۷، ۵۱].



شکل ۲ - روند همگرایی تابع هزینه اتروپی مقاطع مدل 1D-CNN شبکه در داده‌های آموزش دامنه مبدأ و داده‌های اعتبارسنجی طی حداکثر ۱۰۰ دوره آموزشی.

خط‌چین عمودی در شکل ۲، دوره‌ای را مشخص می‌کند که میانگین تابع هزینه اعتبارسنجی در آن به کمینه مقدار خود رسیده است. پارامترهای مدل متناظر با این دوره به‌عنوان مدل پایه انتخاب شدند و سپس برای استخراج ویژگی‌های مرجع، محاسبه میانگین و کوواریانس فضای ویژگی و اجرای مازول‌های تشخیص و جبران رانش مورد استفاده قرار گرفتند [۲۰، ۲۳، ۲۸]. شایان ذکر است که داده‌های دامنه مقصد آزمون، شامل دسته‌های ۸ تا ۱۰، در ترسیم منحنی‌های آموزش و اعتبارسنجی، انتخاب دوره بهینه و تنظیم پارامترهای مدل دخالتی نداشته‌اند. بنابراین، این فرآیند با راهبرد تقسیم زمانی داده‌ها و الزامات جلوگیری از نشت اطلاعات مطرح شده در بخش ۳-۳ سازگار است [۴، ۳۱، ۳۹].

۵-۲- تحلیل نتایج طبقه‌بندی در حضور رانش

Adaptive Moment Estimation (Adam)^۱

در ارزیابی عملکرد طبقه‌بندی، چهار روش مبنا شامل PCA+SVM، ویژگی‌های دستی+MLP، روش مبتنی بر SOM/OSC، و روش پیشنهادی مبتنی بر مدل 1D-CNN سبک همراه با جبران رانش در نظر گرفته شده‌اند [۵۸، ۵۳، ۱۲]. انتخاب این روش‌ها از آن جهت اهمیت دارد که هر یک نماینده یک خانواده متفاوت از راهکارهای مقابله با رانش هستند: روش‌های آماری کلاسیک، روش‌های مبتنی بر طراحی ویژگی و روش‌های عمیق سبک [۱۳، ۱۶، ۳۱].

جدول ۴- مقایسه عملکرد روش پیشنهادی با روش‌های مرجع در شرایط دارای رانش

توضیح	وضعیت معناداری	مقدار p	بازه اطمینان ۹۵٪	ΔAcc (%)	امتیاز F1	دقت کلی بعد از جبران (%)	دقت کلی قبل از جبران (%)	روش
حساس به جابه‌جایی توزیع و تغییرات غیرخطی	معنادار ($p < 0.05$)	$6/34 \times 10^{-10}$	[۸۳/۳۵، ۸۴/۸۵]	$\pm 0.7/5/5$	0.825 ± 0.012	$84/1 \pm 0.9$	$78/0 \pm 4/8$	PCA + SVM
وابسته به کیفیت ویژگی‌های استخراج شده	معنادار ($p < 0.05$)	$6/38 \times 10^{-10}$	[۸۰/۶۱، ۸۱/۹۹]	$\pm 0.4/6/7$	0.798 ± 0.015	$81/3 \pm 1/1$	$74/1 \pm 9/2$	ویژگی‌های دستی + MLP
پایداری بهتر از روش‌های کلاسیک ساده	معنادار ($p < 0.05$)	$1/65 \times 10^{-10}$	[۸۵/۱۶، ۸۶/۸۴]	$\pm 0.8/5/4$	0.849 ± 0.010	$86/0 \pm 0.8$	$80/2 \pm 0.9$	روش مبتنی بر SOM/OSC
بهترین تعادل بین دقت، پایداری و جبران رانش	مرجع	-	[۹۱/۳۹، ۹۲/۲۱]	$\pm 0.1/8/92$	0.909 ± 0.010	$91/8 \pm 0.7$	$83/7 \pm 0.6$	روش پیشنهادی

جدول ۴ مقایسه عملکرد این روش‌ها را در شرایط دارای رانش نشان می‌دهد. میانگین و انحراف معیار مقادیر محاسبه شده، حاصل از ۱۰ اجرای مستقل است. این روش، وابستگی میان نتایج قبل و بعد از جبران را در محاسبه‌ی پراکندگی لحاظ می‌کند [۵۴].


مطابق جدول ۴، روش پیشنهادی با دستیابی به دقت نهایی ۹۱/۸ درصد و مقدار امتیاز F1 برابر ۰/۹۰۹، بهترین عملکرد را در میان روش‌های مقایسه‌ای نشان می‌دهد. مقدار ΔAcc برابر ۸/۱ درصد نیز نشان می‌دهد که سازوکار جبران رانش توانسته است بخش قابل توجهی از افت عملکرد ناشی از رانش را بازیابی کند. این رفتار، با یافته‌های موجود در ادبیات سازگار است. زیرا شبکه‌های پیچشی یک‌بعدی در تحلیل سیگنال‌های حسگری، به دلیل قابلیت استخراج خودکار ویژگی‌های محلی و سلسله‌مراتبی، نسبت به روش‌های مبتنی بر ویژگی‌های دستی تعمیم‌پذیری بیشتری دارند [۵۱، ۱۶]. از سوی دیگر، ترکیب این بازنمایی عمیق با راهبرد جبران در فضای ویژگی، می‌تواند بخشی از تغییرات ناشی از رانش را از مؤلفه‌های مرتبط با نوع گاز تفکیک کند [۲۳، ۲۸].

برای اعتبارسنجی آماری و بررسی اینکه بهبود عملکرد روش پیشنهادی نسبت به روش‌های مرجع ناشی از تصادف نیست، آزمون t زوجی دوطرفه^۱ با سطح معناداری $\alpha = 0.05$ بر مقادیر معیار عملکرد حاصل از تکرارهای متناظر آزمایش اعمال شد [۵۴]. مطابق با توصیه‌های روش‌شناختی ارزیابی مدل‌های یادگیری ماشین [۵۴]، فرضیه صفر (H_0) بر برابری میانگین عملکرد روش پیشنهادی و هر یک از روش‌های مرجع استوار بود. پیش از انجام آزمون، نرمال بودن اختلاف عملکردهای زوجی بررسی شد. برای

^۱Two-sided paired t-test

کنترل خطای ناشی از مقایسه‌های چندگانه، مقادیر p با روش اصلاحی Holm تعدیل شدند [۵۴]. افزون بر مقادیر p تعدیل شده، اندازه اثر و بازه اطمینان ۹۵ درصد اختلاف میانگین عملکرد نیز گزارش گردید.

چنانکه در جدول ۴ ارائه شده است، نتایج تحلیل آماری مقایسه روش پیشنهادی با روش‌های PCA+SVM، روش ویژگی‌های دستی+MLP و روش SOM/OSC نشان‌دهنده رد فرضیه صفر با درجه اطمینان بسیار بالا در تمامی موارد است [۵۴]. با توجه به اینکه مقادیر p در تمامی مقایسه‌ها بسیار کوچک‌تر از آستانه معناداری ۰/۰۵ است، برتری عملکرد روش پیشنهادی در جبران رانش حسگرهای گازی MOS، با توجه به آزمون آماری انجام شده، تفاوت عملکرد در سطح معناداری ۰/۰۵ معنادار است [۵۴]. جزئیات مقادیر شاخص‌های عملکردی به همراه بازه اطمینان (CI) ۹۵ درصد و مقادیر p مربوطه، در جدول ۴ ارائه شده است. برای شفاف‌سازی اثر جبران رانش بر عملکرد طبقه‌بندی، شکل ۳ مقایسه دقت مدل‌های مختلف را قبل و بعد از جبران رانش نشان می‌دهد. همان‌طور که دیده می‌شود، همه روش‌ها در حضور رانش افت عملکرد دارند، اما روش پیشنهادی بیشترین بازیابی دقت را پس از جبران رانش فراهم می‌کند.



شکل ۳- مقایسه دقت طبقه‌بندی قبل و بعد از جبران رانش برای روش‌های پایه و مدل 1D-CNN سبک پیشنهادی.

۳-۵- ارزیابی کارایی جبران رانش

برای سنجش مستقیم کیفیت جبران‌سازی، از دو شاخص اصلی استفاده می‌شود: بهبود دقت پس از جبران و کاهش فاصله توزیعی بین داده‌های مرجع و داده‌های جبران‌شده. از دیدگاه نظری، اگر جبران رانش به‌درستی انجام شود، توزیع ویژگی‌های داده‌های رانش‌یافته، باید به توزیع اولیه نزدیک شود و در نتیجه عملکرد طبقه‌بندی نیز به وضعیت مرجع بازگردد [۲۰، ۲۳، ۲۸، ۵۷]. جدول ۵ نتایج ارزیابی جبران رانش را برای چند راهبرد مختلف نشان می‌دهد. واگرایی کولبک-لایبلر برای مقایسه‌ی توزیع ویژگی‌های


دامنه‌ی مقصد با توزیع مرجع دامنه‌ی مبدأ محاسبه شد [۵۷]. برای جلوگیری از ناپایداری عددی ناشی از احتمال‌های صفر، مقدار ϵ به برآورد احتمال‌ها افزوده شد. از آنجا که واگرایی KL نامتقارن است، جهت محاسبه، به صورت $D_{KL}(P_{source} || P_{target})$ در تمام روش‌ها ثابت نگه داشته شد [۵۷].

جدول ۵- ارزیابی کارایی جبران رانش


تفسیر	زمان استنتاج/پاسخ (ms)	واگرایی کولبک-لایبلر (D_{KL})	ΔAcc (%)	دقت نهایی (%)	روش
رانش کنترل نشده و اختلاف توزیعی زیاد است	$\pm 1/11/2$	$\pm 482/0/25$	$\pm 0/0/0$	$\pm 7/830/6$	بدون جبران
بازیابی مناسب، اما پرهزینه و وابسته به داده مرجع جدید	$\pm 8/11/3$	$\pm 214/0/18$	$\pm 7/5/4$	$\pm 4/89/8$	جبران سنتی مبتنی بر بازکالیبراسیون
بهبود متوسط در کاهش فاصله توزیعی	$\pm 5/12/4$	$\pm 263/0/21$	$\pm 4/4/5$	$\pm 1/88/7$	انطباق دامنه کلاسیک (MMD)
بهترین هم‌ترازی توزیع و بیشترین بازیابی دقت	$\pm 4/11/2$	$\pm 137/0/12$	$\pm 1/8/3$	$\pm 8/91/7$	روش پیشنهادی

برای تکمیل ارزیابی عددی، شکل ۴ مقایسه‌ای بصری میان پروفایل ویژگی‌های استخراج شده پیش از جبران و ویژگی‌های اصلاح شده پس از جبران ارائه می‌کند. در شکل ۴-الف، ویژگی‌های دامنه مقصد پیش از جبران نسبت به پروفایل مرجع دامنه مبدأ دارای جابه‌جایی و پراکندگی بیشتری هستند که بیانگر اثر رانش زمانی در فضای ویژگی است. در شکل ۴-ب، پس از اعمال شبکه 1D-CNN سبک و نگاشت جبران تطبیقی در فضای ویژگی، پروفایل‌های مربوط به دسته‌های مختلف داده به ناحیه مرجع نزدیک‌تر شده و میزان پراکندگی میان دسته‌ها کاهش می‌یابد. این روند با هدف انطباق توزیع‌های دامنه مبدأ و مقصد در روش پیشنهادی سازگار است [۲۰، ۲۳، ۲۸].

برای تکمیل ارزیابی کیفی جبران رانش، در شکل ۵، نمایش دوبعدی توزیع ویژگی‌های استخراج شده با استفاده از t-SNE قبل و بعد از اعمال جبران رانش ارائه می‌شود. نمایش دوبعدی t-SNE صرفاً برای ارائه‌ی یک برداشت کیفی از ساختار فضای ویژگی استفاده شده است و به دلیل وابستگی آن به پارامترهای اجرایی و مقداردهی اولیه، به عنوان معیار کمی هم‌ترازی توزیع‌ها تفسیر نمی‌شود. مطابق این نمایش، در حالت پیش از جبران، نمونه‌های مربوط به دامنه‌های مختلف و گازهای متفاوت دارای هم‌پوشانی بیشتری هستند و خوشه‌ها با مرزبندی ضعیف‌تری ظاهر می‌شوند. در مقابل، پس از اعمال جبران رانش، ویژگی‌ها به نواحی مترکم‌تر و منسجم‌تری منتقل شده‌اند، هم‌پوشانی دامنه‌ها کاهش یافته و جداسازی خوشه‌های مربوط به گازهای مختلف به‌طور محسوسی بهتر شده است. این نتیجه با تحلیل‌های کمی ارائه‌شده در این بخش هم‌راستا بوده و نشان می‌دهد که جبران رانش علاوه بر بهبود دقت طبقه‌بندی، باعث افزایش تفکیک‌پذیری فضای ویژگی نیز می‌شود [۵۵-۵۷].



شکل ۴- نمایش نماینده‌ای از پروفایل ویژگی حسگر پیش و پس از جبران رانش. (الف) پروفایل ویژگی تحت تأثیر رانش در فضای ویژگی اولیه (ب) پروفایل ویژگی جبران‌شده پس از اعمال مدل پیشنهادی 1D-CNN سبک و جبران‌سازی تطبیقی در فضای ویژگی.



شکل ۵- مقایسه نمایش دوبعدی توزیع ویژگی‌های استخراج‌شده قبل و بعد از جبران رانش با استفاده از t-SNE.

همان‌گونه که در شکل ۴ مشاهده می‌شود، جبران‌سازی موجب کاهش اختلاف بصری میان پروفایل ویژگی‌های دامنه مقصد و توزیع مرجع شده است. این مشاهده کیفی با نتایج کمی جدول ۵ هم‌راستا است. به‌طوری‌که مقدار واگرایی کولبک-لایبیلر برای روش پیشنهادی به ۰/۱۳۷ کاهش یافته و دقت طبقه‌بندی از ۸۳/۷ درصد پیش از جبران به ۹۱/۸ درصد پس از جبران رسیده است. بنابراین، شکل ۴ شواهد بصری مکملی برای نزدیک‌تر شدن توزیع ویژگی‌های جبران‌شده به توزیع مرجع فراهم می‌کند. هرچند قضاوت نهایی درباره میزان موفقیت جبران باید بر اساس شاخص‌های کمی، از جمله ΔAcc ، D_{KL} و معیارهای طبقه‌بندی، انجام شود [۵۵-۵۷].

نتایج کمی جدول ۵ نیز این برداشت بصری را تأیید می‌کنند. روش پیشنهادی کمترین مقدار واگرایی کولبک-لایبلر، یعنی ۰/۱۳۷، را به دست آورده است. این نتیجه نشان می‌دهد که ویژگی‌های جبران‌شده نسبت به سایر روش‌ها بیشترین نزدیکی را به توزیع مرجع دارند. کاهش واگرایی کولبک-لایبلر و افزایش دقت در این آزمایش‌ها هم‌زمان مشاهده شده‌اند و از هم‌راستایی این دو شاخص پشتیبانی می‌کنند. چنین نتیجه‌ای با مبانی انطباق دامنه همسو است. زیرا در این دسته از روش‌ها، هم‌ترازسازی بازنمایی میان دامنه مبدأ و مقصد یکی از پیش‌شرط‌های اصلی حفظ تعمیم‌پذیری مدل محسوب می‌شود [۲۳، ۲۸، ۲۹]. در مقابل، اگرچه روش‌های بازکالیبراسیون سنتی نیز می‌توانند بهبود مناسبی ایجاد کنند، اما وابستگی آن‌ها به داده‌برداری مجدد و مداخله انسانی، کاربرد آن‌ها را در سامانه‌های برخط و لبه‌ای محدود می‌کند [۱۲، ۳۱، ۵۰].

۴-۵- مقایسه‌ی روش پیشنهادی با روش‌های کلاسیک و یادگیری عمیق

نتایج جدول‌های ۴ و ۵ نشان می‌دهد که روش پیشنهادی نسبت به دو گروه اصلی از روش‌های موجود، یعنی روش‌های کلاسیک و روش‌های عمیق سنگین، مزیت نسبی دارد. در مقایسه با روش‌های کلاسیک مانند PCA+SVM، علت اصلی برتری، توانایی مدل در نمایش روابط غیرخطی و تغییرات پیچیده زمانی است. روش‌های کلاسیک عموماً به تبدیل‌های خطی یا تقریباً خطی تکیه دارند و در نتیجه در مواجهه با رانش‌های چندمنشأیی یا تدریجی، عملکرد آن‌ها کاهش می‌یابد [۱۲، ۵۳، ۵۸].

در مقایسه با روش‌های مبتنی بر ویژگی‌های دستی، مزیت اصلی روش پیشنهادی، در حذف وابستگی به طراحی تجربی ویژگی‌هاست. در سامانه‌های بویایی الکترونیکی، ویژگی‌های دستی معمولاً تحت تأثیر تجربه طراح، نوع سنسور و شرایط محیطی قرار می‌گیرند. در حالی که یک مدل عمیق سبک می‌تواند الگوهای مؤثر را مستقیماً از داده بیاموزد [۱۱، ۱۶، ۵۱]. همچنین، در مقایسه با روش‌های عمیق سنگین‌تر، رویکرد حاضر با بهره‌گیری از معماری سبک، هزینه محاسباتی کمتری دارد و برای استقرار روی گره‌های IoT و میکروکنترلرها عملی‌تر است [۱۲، ۱۷].

۵-۵- تحلیل کارایی محاسباتی و قابلیت اجرا روی لبه

در کاربردهای واقعی، تنها دستیابی به دقت بالا کافی نیست، بلکه مدل باید از نظر حافظه، تعداد عملیات و زمان پاسخ نیز برای پیاده‌سازی روی سخت‌افزارهای کم‌مصرف مناسب باشد. این مسئله در سامانه‌های حسگری لبه‌ای اهمیت ویژه‌ای دارد، زیرا منابع پردازشی و انرژی در این پلتفرم‌ها محدود است [۱۷-۱۹]. جدول ۶ مقایسه پیچیدگی محاسباتی روش‌های مختلف را نشان می‌دهد. زمان پاسخ گزارش شده شامل پیش‌پردازش، استخراج ویژگی، اجرای مدل طبقه‌بندی و اجرای ماژول جبران رانش است.

جدول ۶- مقایسه پیچیدگی محاسباتی روش‌ها

قابلیت بالقوه برای استقرار روی لبه بر اساس پیچیدگی محاسباتی	زمان پاسخ (ms)	FLOPs	تعداد پارامتر	روش
محدود	۴۲/۸	۴۸/۶ M	۱۲۴۰۰۰	MLP / CNN متعارف
متوسط	۱۸/۵	۶/۹ M	۱۸۵۰۰۰	SVM + ویژگی‌های دستی
نسبتاً مناسب	۲۳/۱	۹/۷ M	۲۶۴۰۰۰	روش مبتنی بر SOM/OSC
مناسب	۱۱/۴	۴/۱ M	۱۲۸۰۰۰	روش پیشنهادی 1D-CNN سبک

طبق جدول ۶، در میان مدل‌های عصبی مقایسه‌شده، روش پیشنهادی با ۱۲۸ هزار پارامتر و ۴/۱ میلیون عملیات شناور، کمترین تعداد پارامتر و کمترین تعداد عملیات محاسباتی تخمینی را دارد. همچنین زمان پاسخ ۱۱/۴ میلی‌ثانیه نشان می‌دهد که مدل برای کاربردهای برخط مناسب است. نتایج جدول ۶ نشان‌دهنده قابلیت بالقوه‌ی روش پیشنهادی برای استقرار روی سامانه‌های لبه‌ای است. با این حال، تأیید قطعی قابلیت اجرا نیازمند اندازه‌گیری روی سخت‌افزار هدف و گزارش حافظه، مصرف انرژی و زمان پاسخ واقعی است [۱۷-۱۹]. این نتیجه از منظر عملی اهمیت بالایی دارد، زیرا نشان می‌دهد که می‌توان بدون استفاده از معماری‌های سنگین، به توازن مناسبی میان دقت و سرعت دست یافت. چنین ویژگی‌ای برای کاربردهایی مانند پایش پیوسته کیفیت هوا، تشخیص نشت گاز در محیط‌های صنعتی، و سامانه‌های قابل حمل پزشکی اهمیت زیادی دارد [۱۲، ۱۸، ۱۹].

۶-۵- نقاط قوت روش پیشنهادی

بر اساس نتایج به‌دست آمده، مهم‌ترین نقاط قوت روش پیشنهادی عبارت‌اند از:

- حفظ بهتر دقت طبقه‌بندی در حضور رانش نسبت به روش‌های کلاسیک و نیمه‌کلاسیک.
- بهبود معنی‌دار در شاخص ΔAcc و کاهش فاصله توزیعی پس از جبران.
- قابلیت استخراج خودکار ویژگی‌های مقاوم بدون اتکا به طراحی دستی.
- پیچیدگی محاسباتی پایین و امکان استقرار روی بستر لبه.
- قابلیت توسعه‌پذیری برای ترکیب با راهبردهای یادگیری انتقالی و انطباق دامنه پیشرفته.

۷-۵- نقاط ضعف و محدودیت‌های روش پیشنهادی

با وجود مزایای یادشده، روش حاضر همچنان با چند محدودیت روبه‌رو است. نخست، عملکرد آن به کیفیت داده‌های مرجع اولیه وابسته است و در صورتی که داده مرجع نماینده مناسبی از شرایط واقعی نباشد، دقت جبران کاهش می‌یابد [۳۱، ۵۰]. دوم، در سناریوهایی که تغییرات دما، رطوبت یا آلودگی سطح حسگر شدید باشد، تفکیک میان رانش و تغییر واقعی ناشی از گاز دشوارتر خواهد شد [۱۲، ۳۴]. سوم، جبران در فضای ویژگی اگرچه از نظر محاسباتی کارآمد است، اما ممکن است همه سازوکارهای فیزیکی و شیمیایی ایجاد رانش را به‌طور کامل مدل نکند [۳۲، ۳۴]. در نهایت، برای تأیید کامل استحکام روش، لازم است ارزیابی آن روی داده‌های بلندمدت‌تر، شرایط محیطی متنوع‌تر و آرایه‌های حسگری مختلف انجام شود [۳۱، ۳۲].

۶- نتیجه‌گیری

در این پژوهش، یک چارچوب سبک و تطبیقی برای تشخیص و جبران رانش بلندمدت در آرایه‌های حسگر گازی نیم‌رسانای اکسید فلزی ارائه شد. هدف اصلی، حفظ دقت طبقه‌بندی گازها در شرایط تغییر تدریجی توزیع داده‌ها و در عین حال، کاهش هزینه محاسباتی برای کاربردهای مبتنی بر اینترنت اشیاء و محاسبات لبه بود. چارچوب پیشنهادی از سه مؤلفه اصلی تشکیل شد: شبکه پیچشی یک‌بعدی سبک برای استخراج خودکار ویژگی‌های زمانی، فاصله‌ماهالانویس برای پایش انحراف ویژگی‌های جدید از توزیع مرجع و روش انطباق دامنه خصمانه زیرفضایی برای کاهش اختلاف میان دامنه مبدأ و مقصد. در این ساختار، فرآیند انطباق بدون استفاده از برچسب‌های دامنه مقصد انجام گرفت. بنابراین، وابستگی سامانه به باز کالیبراسیون فیزیکی، داده‌های برچسب‌دار جدید و مداخله مستمر انسانی کاهش یافت.

ارزیابی چارچوب پیشنهادی بر روی مجموعه داده مرجع آرایه حسگرهای گازی، شامل پاسخ ۱۶ حسگر MOS به شش گاز در یک دوره ۳۶ ماهه، انجام شد. برای شبیه‌سازی واقع‌بینانه رانش زمانی و جلوگیری از نشت اطلاعات، داده‌ها به صورت زمانی تقسیم شدند. به گونه‌ای که دسته‌های ۱ تا ۵ برای آموزش، دسته‌های ۶ و ۷ برای اعتبارسنجی و دسته‌های ۸ تا ۱۰ برای آزمون نهایی

در نظر گرفته شدند. علاوه بر این، تمام مراحل آموزش و ارزیابی در ۱۰ اجرای مستقل با بذره‌های تصادفی متفاوت تکرار شد. این راهبرد ارزیابی موجب شد عملکرد مدل در برابر داده‌های متعلق به دوره‌های زمانی آینده و تحت تأثیر رانش، بدون اختلاط تصادفی داده‌های آموزش و آزمون بررسی شود.

نتایج نشان داد که رانش زمانی موجب کاهش دقت مدل پایه به $83/7\%$ درصد می‌شود. در حالی که پس از اعمال روش پیشنهادی، دقت طبقه‌بندی به $91/8\%$ درصد و امتیاز F1 به $0/909$ افزایش یافت. بنابراین، چارچوب پیشنهادی توانست بهبود دقتی معادل $8/1$ درصد ایجاد کند. همچنین، مقایسه با روش‌های PCA+SVM، ویژگی‌های دستی همراه با MLP و روش SOM/OSC نشان داد که روش پیشنهادی از نظر دقت نهایی، امتیاز F1 و میزان بازیابی عملکرد پس از جبران رانش، نتیجه بهتری به دست می‌آورد. نتایج آزمون آماری زوجی گزارش شده نیز نشان داد اختلاف عملکرد روش پیشنهادی با روش‌های مرجع در سطح معناداری $0/05$ معنادار است. این یافته‌ها بیانگر آن است که ترکیب استخراج خودکار ویژگی‌های زمانی با انطباق توزیعی در فضای ویژگی، نسبت به روش‌های متکی بر ویژگی‌سازی دستی یا نگاشت‌های خطی، توان بیشتری در مقابله با تغییرات غیرخطی و بلندمدت پاسخ حسگر دارد.

بررسی شاخص‌های توزیعی نیز اثربخشی جبران رانش را تأیید کرد. مقدار واگرایی کولبک-لایبلر میان ویژگی‌های دامنه مرجع و ویژگی‌های دامنه مقصد، در حالت بدون جبران برابر $0/482$ بود که با استفاده از روش پیشنهادی به $0/137$ کاهش یافت. این مقدار، کمتر از نتایج حاصل از باز کالیبراسیون سنتی و انطباق دامنه کلاسیک مبتنی بر MMD بود. کاهش هم‌زمان واگرایی توزیعی و افزایش دقت طبقه‌بندی نشان می‌دهد که نگاشت تطبیقی پیشنهادی، ضمن نزدیک کردن توزیع ویژگی‌های مقصد به توزیع مرجع، بخش قابل توجهی از اطلاعات تفکیک‌کننده کلاس‌های گاز را نیز حفظ کرده است. مشاهدات کیفی حاصل از پروفایل ویژگی‌ها و نمایش دوبعدی t-SNE نیز با نتایج کمی هم‌راستا بود و انسجام بیشتر خوشه‌ها و کاهش هم‌پوشانی ویژگی‌ها را پس از جبران نشان داد. با این حال، تفسیر نهایی عملکرد بر معیارهای کمی دقت، امتیاز ΔAcc ، F1 و واگرایی کولبک-لایبلر استوار است و نمایش t-SNE صرفاً به عنوان شاهد بصری مکمل در نظر گرفته می‌شود.

از نظر پیچیدگی محاسباتی، مدل پیشنهادی با ۱۲۸ هزار پارامتر قابل آموزش، حدود $4/1$ میلیون عملیات ممیز شناور و میانگین زمان پاسخ $11/4$ میلی ثانیه برای هر نمونه، توازن مناسبی میان دقت و هزینه محاسباتی برقرار کرد. استفاده از پیچش تفکیک‌پذیر عمقی، میانگین‌گیری سراسری و نمایش ویژگی ۶۴ بعدی، موجب کاهش تعداد پارامترها و عملیات محاسباتی در مقایسه با شبکه‌های متعارف شد. این نتایج، قابلیت بالقوه چارچوب را برای پردازش برخط در سامانه‌های پایش کیفیت هوا، تشخیص نشت گاز و تجهیزات حسگری قابل حمل نشان می‌دهد. با وجود این، از آنجا که ارزیابی حاضر در محیط محاسباتی شبیه‌سازی انجام شده است، نتایج مربوط به زمان پاسخ و پیچیدگی محاسباتی باید به عنوان شواهد اولیه امکان استقرار روی لبه تفسیر شوند. تأیید قطعی این قابلیت به پیاده‌سازی مدل روی سخت‌افزار هدف و اندازه‌گیری مستقیم حافظه مصرفی، انرژی، تأخیر و پایداری اجرای بلندمدت نیاز دارد.

در مجموع، یافته‌های این پژوهش نشان می‌دهد که ترکیب شبکه 1D-CNN سبک، پایش آماری مبتنی بر فاصله ماهالانوبیس و انطباق دامنه خصمانه زیرفضایی می‌تواند راهکاری مؤثر برای کاهش افت عملکرد ناشی از رانش بلندمدت حسگرهای گازی MOS فراهم کند. مزیت اصلی این چارچوب، جبران بدون نظارت رانش در دامنه مقصد، استخراج خودکار ویژگی‌ها، کاهش وابستگی به کالیبراسیون مجدد و برخورداری از پیچیدگی محاسباتی نسبتاً پایین است. با این حال، عملکرد روش به کیفیت و نمایندگی داده‌های مرجع، ثبات رابطه میان کلاس گاز و ساختار ویژگی‌ها و امکان تفکیک رانش حسگر از تغییرات واقعی شرایط محیطی وابسته است. همچنین، هم‌تراز کردن توزیع ویژگی‌ها به تنهایی تضمین‌کننده حفظ کامل ساختار کلاس‌ها نیست و در رانش‌های شدید یا تغییرات اساسی شرایط کاری، احتمال انطباق منفی وجود دارد.

در ادامه این پژوهش، پیشنهاد می‌شود چارچوب ارائه‌شده روی بردهای واقعی محاسبات لبه و در شرایط عملیاتی متنوع از نظر دما، رطوبت، غلظت گاز و آلودگی سطح حسگر ارزیابی شود [۶، ۳۲، ۳۵، ۳۹]. بررسی آرایه‌های حسگری و مجموعه داده‌های مستقل، گزارش معیارهای اختصاصی تشخیص رانش مانند نرخ هشدار کاذب، نرخ کشف و تأخیر تشخیص، و تحلیل حساسیت مدل نسبت به آستانه فاصله مایلانویس نیز می‌تواند اعتبار و تعمیم‌پذیری نتایج را افزایش دهد. افزون بر این، استفاده از راهبردهای انطباق آگاه از کلاس، یادگیری پیوسته، تشخیص نمونه‌های خارج از توزیع و روش‌های کوانتیزه‌سازی و هرس شبکه می‌تواند به حفظ بهتر مرزهای تصمیم، کاهش خطر انطباق منفی و بهبود کارایی مدل روی سخت‌افزارهای کم‌مصرف کمک کند [۱۷، ۱۸، ۲۷، ۲۹]. در نهایت، ترکیب مدل داده‌محور پیشنهادی با اطلاعات فیزیکی و شیمیایی حسگر می‌تواند زمینه توسعه سامانه‌های گازسنجی پایدارتر، تفسیرپذیرتر و قابل اعتمادتر را برای کاربردهای بلندمدت فراهم سازد [۳، ۷، ۳۲-۳۴].

مراجع

- S. L. Ullo and G. R. Sinha, "Advances in smart environment monitoring systems using IoT and sensors," *Sensors*, vol. 20, no. 11, p. 3113, 2020.
1. L. Xue, Y. Li, and Y. Deng, "Multicomponent porous metal oxide semiconductors for advanced gas sensing," *Micro Nano Sci.*, vol. 1, p. 2, 2025.
 2. Pathania, N. Dhanda, R. Verma, A.-C. A. Sun, P. Thakur, and A. Thakur, "Review-Metal oxide chemoresistive gas sensing mechanism, parameters, and applications," *ECS Sensors Plus*, 2024.
 3. J. Fonollosa, I. Rodríguez-Luján, and R. Huerta, "Chemical gas sensor array dataset," *Data in Brief*, vol. 3, pp. 85–89, 2015.
 4. Shahid et al., "Carbon based sensors for air quality monitoring networks; middle east perspective," *Front. Chem.*, vol. 12, 2024.
 5. W. Reimringer and C. Bur, "Promoting quality in low-cost gas sensor devices for real-world applications," *Frontiers in Sensors*, vol. 4, 2023.
 6. D. Degler, U. Weimar, and N. Barsan, "Current understanding of the fundamental mechanisms of doped and loaded semiconducting metal-oxide-based gas sensing materials," *ACS Sensors*, 2019.
 7. W. Wang, C. Wang, K. Li, J. Wang, and X. Wang, "Advances in functional guest materials for resistive gas sensors," *RSC Advances*, vol. 12, pp. 24614–24632, 2022.
 8. S. M. Scott, D. James, and Z. Ali, "Data analysis for electronic nose systems," *Microchimica Acta*, vol. 156, no. 3, pp. 183–207, 2006.
 9. C. Distanto, M. Leo, P. Siciliano, and K. C. Persaud, "On the study of feature extraction methods for an electronic nose," *Sensors and Actuators B: Chemical*, vol. 87, no. 2, pp. 274–288, 2002.
 10. Fonollosa, S. Sheik, R. Huerta, and S. Marco, "Reservoir computing compensates slow response of chemosensor arrays exposed to fast varying gas concentrations in continuous monitoring," *Sensors and Actuators B: Chemical*, vol. 215, pp. 618–629, 2015.
 11. F. Chollet, "Xception: Deep learning with depthwise separable convolutions," in *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, 2017, pp. 1251–1258.
 12. Dang, P. Pang, and J. Lee, "Depth-Wise separable convolution neural network with residual connection for hyperspectral image classification," *Remote Sensing*, vol. 12, no. 20, p. 3408, 2020.
 13. G. Howard et al., "MobileNets: Efficient convolutional neural networks for mobile vision applications," *arXiv preprint arXiv:1704.04861*, 2017.
 14. S. Han, H. Mao, and W. J. Dally, "Deep compression: Compressing deep neural networks with pruning, trained quantization and Huffman coding," *International Conference on Learning Representations (ICLR)*, 2016.
 15. Sandler, A. Howard, M. Zhu, A. Zhmoginov, and L.-C. Chen, "MobileNetV2: Inverted residuals and linear bottlenecks," in *Proc. CVPR*, 2018, pp. 4510–4520.
 16. Lane, S. Bhattacharya, A. Mathur, P. Georgiev, C. Forlivesi, and F. Kawsar, "Squeezing deep learning into mobile and embedded devices," *IEEE Pervasive Computing*, vol. 16, no. 3, pp. 82–88, 2017.
 17. J. X. Leon-medina et al., "Joint distribution adaptation for drift correction in electronic nose type sensor arrays," *IEEE Access*, vol. 8, pp. 134413–134421, 2020.

18. Amiri, M. R. V. Narayana, et al., "Nanostructured metal oxide-based acetone gas sensors: A review," *Sensors*, vol. 20, no. 11, p. 3096, 2020.
19. L. Zhang and D. Zhang, "Domain adaptation extreme learning machine for drift compensation in e-nose systems," *IEEE Transactions on Instrumentation and Measurement*, vol. 64, no. 9, pp. 2510–2520, 2015.
20. Long, Y. Cao, J. Wang, and M. Jordan, "Learning transferable features with deep adaptation networks," in *International Conference on Machine Learning (ICML)*, 2015, pp. 97–105.
21. Y. Ganin, E. Ustinova, H. Ajakan, P. Germain, H. Larochelle, F. Laviolette, M. Marchand, and V. Lempitsky, "Domain-adversarial training of neural networks," *Journal of Machine Learning Research*, vol. 17, no. 59, pp. 1–35, 2016.
22. E. Tzeng, J. Hoffman, K. Saenko, and T. Darrell, "Adversarial discriminative domain adaptation," in *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, Honolulu, HI, USA, 2017, pp. 2962–2971.
23. B. Fernando, A. Habrard, M. Sebban, and T. Tuytelaars, "Unsupervised visual domain adaptation using subspace alignment," in *Proceedings of the IEEE International Conference on Computer Vision (ICCV)*, Sydney, Australia, 2013.
24. Y. Zhu, F. Zhuang, J. Wang, J. Chen, and D. Wang, "Deep subdomain adaptation network for image classification," *IEEE Transactions on Neural Networks and Learning Systems*, vol. 31, no. 2, pp. 1–13, 2020.
25. Y. Ganin and V. Lempitsky, "Unsupervised domain adaptation by backpropagation," in *International Conference on Machine Learning (ICML)*, 2015, pp. 1180–1189.
26. B. Sun and K. Saenko, "Deep CORAL: Correlation alignment for deep domain adaptation," in *Proc. ECCV Workshops*, 2016.
27. Y. H. Kim, J. H. Lee, and S. O. Park, "Deep learning-based calibration and drift compensation for metal oxide semiconductor gas sensors in environmental internet of things," *IEEE Internet of Things Journal*, vol. 8, no. 15, pp. 12041–12052, 2021.
28. M. Jose and J. G. J. Olivier, "Drift compensation of commercial water quality sensors using machine learning to extend the calibration lifetime," *Journal of Ambient Intelligence and Humanized Computing*, 2020.
29. X. Zhao, P. Li, K. Xiao, X. Meng, L. Han, and C. Yu, "Sensor drift compensation based on the improved LSTM and SVM multi-class ensemble learning models," *Sensors*, vol. 19, no. 18, p. 3844, 2019.
30. Vergara et al., "Chemical gas sensor drift compensation using classifier ensembles," *Sensors and Actuators B: Chemical*, vol. 166–167, pp. 320–329, 2012.
31. Dey, "Semiconductor metal oxide gas sensors: A review," *Materials Science and Engineering: B*, vol. 229, pp. 206–217, 2018.
32. D. J. Blackwood, "An overview of gas sensing in semiconducting metal oxides," *Sensors and Actuators B: Chemical*, vol. 147, no. 1, pp. 13–20, 2010.
33. Barsan and U. Weimar, "Conduction model of metal oxide gas sensors," *Journal of Electroceramics*, vol. 7, no. 3, pp. 143–167, 2001.
34. Wang, L. Yin, Zhang L, D. Xiang, and R. Gao, "Metal oxide gas sensors: sensitivity and influencing factors," *Sensors*, vol. 10, no. 3, pp. 2088–2106, 2010.
35. M. Kanan, O. M. El-Kadri, I. A. Abu-Yousef, and M. C. Kanan, "Semiconducting metal oxide based sensors for selective gas pollutant detection," *Sensors*, vol. 9, no. 10, pp. 8158–8196, 2009.
36. Gurlo, "Interplay between O₂ and SnO₂, ZnO, and In₂O₃ surface: A key for understanding gas sensing mechanisms," *ChemPhysChem*, vol. 7, no. 10, pp. 2041–2052, 2006.
37. D. Bartholomew and J. W. Morris, "Surface-to-volume ratios in nanostructured semiconductor metal oxides," *Journal of Physical Chemistry C*, vol. 112, no. 14, pp. 5312–5319, 2008.
38. Romano-Filho, L. A. E. M. S. Santos, and R. T. G. de Oliveira, "Long-term drift and instability in metal oxide semiconductor gas sensors: A review of mitigation strategies," *Sensors and Actuators Reports*, vol. 3, p. 100034, 2021.
39. G. F. Fine, L. M. Cavanagh, A. Afonja, and R. Binions, "Metal oxide semi-conductor gas sensors in environmental monitoring," *Sensors*, vol. 10, no. 6, pp. 5469–5502, 2010.
40. S. R. Morrison, *The Chemical Physics of Surfaces*, 2nd ed. Plenum Press, 1990.
41. N. Yamazoe, "Toward new sensors for environmental monitoring and health care," *Sensors and Actuators B: Chemical*, vol. 108, no. 1–2, pp. 2–14, 2005.

42. M. Batzill and U. Diebold, "The surface and materials science of tin oxide," *Progress in Surface Science*, vol. 79, no. 2-4, pp. 47-154, 2005.
43. Z. L. Wang, "Nanostructures of zinc oxide," *Materials Today*, vol. 7, no. 6, pp. 26-33, 2004.
44. L. Linsebigler, G. Lu, and J. T. Yates Jr, "Photocatalysis on TiO₂ surfaces: principles, mechanisms, and selected results," *Chemical Reviews*, vol. 95, no. 3, pp. 735-758, 1995.
45. K. Varghese, D. Gong, M. Paulose, K. G. Ong, and C. A. Grimes, "Hydrogen sensing using titania nanotubes," *Sensors and Actuators B: Chemical*, vol. 93, no. 1-3, pp. 338-344, 2003.
46. J. Ma, Y. Ren, X. Zhou, L. Liu, Y. Zhu, X. Cheng, P. Xu, X. Li, Y. Deng, and D. Zhao, "Silica-templated synthesis of ordered mesoporous tungsten oxide for highly sensitive and selective nitrogen dioxide detection," *Advanced Functional Materials*, vol. 28, no. 6, p. 1705268, 2018.
47. Cantalini, H. T. Sun, M. Faccio, M. Pelino, S. Santucci, L. Lozzi, and M. Passacantando, "NO₂ sensitivity of WO₃ thin film sensors prepared by hot filament vacuum deposition," *Sensors and Actuators B: Chemical*, vol. 31, no. 1-2, pp. 81-87, 1996.
48. M. J. S. P. L. Kumar and V. R. K. M. Rao, "Indium oxide nanostructures for low-temperature gas sensing applications: A review," *Ceramics International*, vol. 47, no. 1, pp. 15-38, 2021.
49. Rudnitskaya, "Calibration update and drift correction for electronic noses and tongues," *Frontiers in Chemistry*, vol. 6, p. 433, 2018.
50. Y. LeCun, Y. Bengio, and G. Hinton, "Deep learning," *Nature*, vol. 521, no. 7553, pp. 436-444, 2015.
51. S. De Vito, E. Massera, M. Piga, L. Martinotto, and G. Di Francia, "On field calibration of an electronic nose for benzene estimation in an urban pollution monitoring station," *Sensors and Actuators B: Chemical*, vol. 129, no. 2, pp. 750-757, 2008.
52. G. Brereton and G. R. Lloyd, "Support vector machines for classification and regression," *Analyst*, vol. 135, no. 2, pp. 230-267, 2010.
53. O. Rainio, J. Teuho, and R. Klén, "Evaluation metrics and statistical tests for machine learning," *Sci. Rep.*, vol. 14, no. 1, p. 6086, Mar. 2024.
54. M. Powers, "Evaluation: from precision, recall and F-measure to ROC, informedness, markedness and correlation," *Journal of Machine Learning Technologies*, vol. 2, no. 1, pp. 37-63, 2011.
55. M. Sokolova and G. Lapalme, "A systematic analysis of performance measures for classification tasks," *Information Processing & Management*, vol. 45, no. 4, pp. 427-437, 2009.
56. T. Cover and J. Thomas, *Elements of Information Theory*, 2nd ed. Hoboken, NJ, USA: Wiley-Interscience, 2006.
57. J. C. Burges, "A tutorial on support vector machines for pattern recognition," *Data Mining and Knowledge Discovery*, vol. 2, no. 2, pp. 121-167, 1998.

Optimization of sigma-delta modulator for medical applications



Sahand University
of Technology

DOR:

[20.1001.1.23223146.1405.12.2.4.3](https://doi.org/10.1001.1.23223146.1405.12.2.4.3)

Journal of Nonlinear
Systems in Electrical
Engineering

Vol. 12, No. 2

Autumn and Winter 2025

ISSN: 2322 – 3146

<http://jnsee.sut.ac.ir>

Yousef Belghisaza, Khalil Monfaredi*, Mousa Yousefi

Department of Electrical and Electronic Engineering, Azarbaijan Shahid Madani
University, Tabriz, Iran.

* Corresponding author email: khmonfaredi@azaruniv.ac.ir

Abstract

This paper presents the design, simulation, and optimization of a second-order discrete-time sigma-delta modulator intended for biomedical signal acquisition. The modulator is implemented in Cadence environment using a standard 180 nm CMOS technology and operates with a signal bandwidth of 500 Hz, targeting neural signal recording applications. The design employs an oversampling ratio (OSR) of 256 and a sampling frequency of 256 kHz. The modulator achieves a maximum SNDR of 76.3 dB, corresponding to an effective number of bits (ENOB) of 12.4 bits. A key contribution is the design of a low-power two-stage operational transconductance amplifier (OTA) with load-capacitor compensation, featuring wide output swing and consuming only 5.26 μ W. The complete modulator consumes 10.7 μ W, including the power dissipated by the OTA and a dynamic 1-bit comparator. The resulting figure of merit (FOM) is 1.98 pJ/conversion-step, demonstrating competitive energy efficiency compared to recent state-of-the-art designs. These results confirm the suitability of the proposed modulator for implantable and portable biomedical devices.

Keywords

Analog-to-digital converter, sigma-delta modulator, analog integrated circuits, two-stage amplifier, second-order modulator, low-power biomedical electronics

1. Short Introduction

Sigma-delta modulators, introduced in the 1960s, have become a cornerstone of high-resolution analog-to-digital conversion due to their inherent noise-shaping capability and low sensitivity to analog circuit non-idealities [1]. Unlike Nyquist-rate converters, sigma-delta modulators utilize oversampling and quantization noise shaping to achieve high resolution at moderate bandwidths, making them particularly attractive for precision measurement and biomedical applications [2, 3].

As CMOS technology scales, challenges such as reduced supply voltages and increased process variations pose significant design difficulties. However, sigma-delta modulators remain a robust solution, although their conversion speed is inherently limited by the oversampling requirement. In the context of low-power implantable biomedical systems, energy-efficient data acquisition with high resolution is essential for monitoring physiological signals such as neural activity, which typically have bandwidths in the range of a few hundred hertz [4, 5].

Motivated by these requirements, this work presents the design of a second-order sigma-delta modulator optimized for brain signal acquisition with a 500 Hz bandwidth. The design focuses on achieving high resolution, low power consumption, and reduced silicon area, while maintaining sufficient robustness for practical biomedical applications.

2. Proposed Work

2.1. System-Level Design Using the Schreier Toolbox

The modulator was initially designed at the behavioral level using the Schreier Delta-Sigma Toolbox [6] in MATLAB. The objective was to determine optimal loop filter coefficients and quantify the sensitivity to non-ideal effects such as finite amplifier gain.

The system-level architecture is depicted in Figure 1. Behavioral simulations show that the peak signal-to-quantization-noise ratio (SQNR) occurs at an input level of -5 dBFS, beyond which integrator saturation degrades performance. This defines the maximum allowable input amplitude for the modulator.

Amplifier gain requirements were also investigated. As illustrated in Figure 2, increasing amplifier gain beyond 40 dB (100 V/V) yields diminishing returns, with SQNR saturating above 90 dB. This provides a clear specification for the analog circuit design.

2.2. Proposed Architecture and Comparative Evaluation

A simplified architecture was developed as an alternative to the Schreier-based design, as shown in Figure 3. This proposed architecture eliminates two summing nodes and uses unity coefficients to reduce circuit complexity.

The dynamic range simulations for both architectures are compared in Figures 4 and 5. The Schreier-based modulator delivers marginally better SQNR (approximately 95 dB versus 89 dB for the proposed structure at 40 dB gain) and improved voltage swing margins. However, the additional complexity of the Schreier design, including non-unity coefficients and extra summing nodes, significantly increases implementation effort and silicon area.

Table 1 summarizes the key trade-offs between the two architectures. Considering these trade-offs, the proposed structure was selected for circuit-level implementation due to its simplicity and lower area overhead.

2.3. Circuit Design and Simulation Results

2.3.1. Operational Transconductance Amplifier (OTA)

2.3.2. Comparator Design

2.3.3. Complete Modulator Simulation

3. Conclusion

This paper has presented the system-level design, comparative evaluation, and circuit implementation of a second-order sigma-delta modulator for biomedical applications. The proposed architecture, selected for its reduced complexity, was implemented in a 180 nm CMOS process. A low-power two-stage OTA with load-capacitor compensation was designed, achieving 40 dB gain and 70° phase margin while consuming 5.26 μ W. The complete modulator achieves 76.3 dB SNDR (12.4 ENOB) over a 500 Hz bandwidth with a total power consumption of 10.7 μ W, corresponding to an FOM of 1.98 pJ/conversion-step. These results validate the suitability of the proposed design for low-power biomedical systems, such as neural signal recorders.

بهینه سازی مدولاتور سیگما - دلتا برای کاربردهای مهندسی پزشکی

یوسف بلقیس آذر^۱، خلیل منفردی^{۲*} و موسی یوسفی^۳

^۱ دانش آموخته کارشناسی ارشد برق الکترونیک، دانشکده فنی و مهندسی، دانشگاه شهید مدنی آذربایجان، تبریز، ایران

^۲ دانشیار گروه مهندسی برق، دانشکده فنی و مهندسی، دانشگاه شهید مدنی آذربایجان، تبریز، ایران

^۳ دانشیار گروه مهندسی برق، دانشکده فنی و مهندسی، دانشگاه شهید مدنی آذربایجان، تبریز، ایران

آدرس پست الکترونیکی نویسنده مسئول: khmonfaredi@azaruniv.ac.ir



دانشگاه صنعتی سهند

DOR:

[20.1001.1.23223146.1405.12.2.4.3](https://doi.org/10.1001.1.23223146.1405.12.2.4.3)

نشریه علمی پژوهشی «مهندسی برق»

دوره ۱۲ - شماره ۲

پاییز و زمستان ۱۴۰۴

صفحات ۷۳ الی ۸۶

ISSN: 2322-3146

<http://jnsee.sut.ac.ir>

تاریخ پذیرش: ۱۴۰۵/۶/۶

تاریخ بازنگری: ۱۴۰۵/۵/۲۶

تاریخ ارسال: ۱۴۰۴/۱۱/۱۲

چکیده

واژه‌های کلیدی

مبدل آنالوگ به دیجیتال

مدولاتور سیگما - دلتا

مدارهای مجتمع آنالوگ

تقویت کننده دوطبقه

مدولاتور مرتبه دوم

الکترونیک پزشکی کم مصرف

در این مقاله طراحی، شبیه سازی و بهینه سازی مدولاتور سیگما-دلتای مرتبه دوم زمان گسسته برای کاربردهای ثبت سیگنال های زیستی ارائه شده است. مدولاتور در محیط نرم افزار Cadence با تکنولوژی 180 nm CMOS پیاده سازی شده و با پهنای باند 500 Hz ، برای کاربردهای ثبت سیگنال های عصبی در نظر گرفته شده است. نسبت فرامونه برداری (OSR) برابر 256 و فرکانس نمونه برداری 256 kHz در نظر گرفته شده و مدولاتور حداکثر نسبت سیگنال به نویز و اعوجاج (SNDR) معادل 76.3 dB دسی بل را ارائه می دهد که معادل 12.4 dB بیت مؤثر (ENOB) است. تقویت کننده عملیاتی ترانس انالوگ دوطبقه با جبران سازی خازن بار، دارای محدوده ولتاژ خروجی وسیع بوده و تنها 5.26 mW توان مصرف می کند. توان مصرفی کل مدولاتور شامل تقویت کننده و مقایسه گر دینامیک یک بیتی، 10.7 mW است که در نتیجه ضریب شایستگی (FOM) برابر $1/98$ پیکوژول بر سطح تبدیل به دست می آید. این نتایج نشان دهنده کارآیی رقابتی طرح پیشنهادی نسبت به طرح های مشابه بوده و مدولاتور پیشنهادی را برای کاربرد در ادوات پزشکی قابل کاشت و قابل حمل مناسب می سازد.

۱- مقدمه

مبدل‌های سیگما-دلتا برای نخستین بار در سال ۱۹۶۰ با انجام تغییراتی در مدولاتور دلتا، پا به عرصه وجود نهادند. دو سال بعد، برای اولین بار از این مبدل‌ها برای تبدیل سیگنال آنالوگ به دیجیتال استفاده شد [۱]. از آن تاریخ، سیستم‌های زیادی از این مبدل‌ها برای کاربردهای مخابراتی و اندازه‌گیری استفاده نموده‌اند. این مبدل‌ها برخلاف سایر مبدل‌های آنالوگ به دیجیتال، مبنای ریاضیاتی نسبتاً پیچیده‌ای دارند و قابلیت بالایی برای کارهای بسیار دقیق با تعداد بیت‌های بالا دارند. از ویژگی‌های بارز این مبدل‌ها، حساسیت کم به اثرات غیرایده‌آل مدارهای آنالوگ و قابلیت شکل‌دهی نویز است که باعث می‌شود به‌عنوان مبدلی کم‌نویز و با دقت بالا مطرح باشند [۲].

با پیشرفت تکنولوژی، دو تغییر اساسی در مدارهای مجتمع رخ داده است: نخست، کوچک‌تر شدن عناصر که به افزایش اثرات غیرایده‌آل منجر می‌شود و دوم، کاهش ولتاژ تغذیه که نسبت سیگنال به نویز را کاهش می‌دهد. بهترین راه برای همگامی با تکنولوژی بدون کاهش بهره‌دهی، استفاده از مبدل سیگما-دلتا است. با این حال، مهم‌ترین محدودیت این مبدل‌ها سرعت پایین آن‌هاست که ناشی از لزوم عملکرد در حالت بیش‌نمونه‌برداری است [۳].

شالوده ادوات قابل کاشت مهندسی پزشکی، سیستم‌های جمع‌آوری اطلاعات و سیستم‌های پردازشی هستند. با توجه به محدودیت تعویض یا شارژ باتری و همچنین محدود بودن انرژی حرارتی متصاعد شده از مدارات پزشکی، این مدارات باید توان بسیار کمی مصرف نمایند [۴]. با توجه به سهولت پردازش و انتقال اطلاعات دیجیتال، داده‌های به‌دست آمده باید توسط مبدل‌های آنالوگ به دیجیتال به سیگنال دیجیتال تبدیل شوند. برای دقت‌های بالا معمولاً استفاده از مدولاتورهای سیگما-دلتا ضروری است [۵].

در این مقاله، مدولاتور سیگما-دلتای مرتبه دوم با دقت بالا برای اندازه‌گیری سیگنال‌های مغزی طراحی شده است. چنین کاربردی دارای پهنای باند ۵۰۰ هرتز است [۶]. برای دستیابی به ضریب شایستگی خوب، لازم است دقت تا حد امکان بالا رفته و توان مصرفی کم باشد. همچنین برای کاهش هزینه، باید مساحت مصرفی تراشه تا حد امکان کم باشد؛ کاهش مساحت تراشه همچنین باعث کاهش پیچیدگی عمل جراحی و فرآیند کاشت مدار در بدن می‌شود.

در این مقاله دو طرح برای مدولاتور مرتبه ۲ بررسی می‌شود. یکی نسخه پیشنهادی جعبه ابزار شرایر^۱ و دیگری نسخه پیشنهادی مولفین. بعد از بحث و بررسی از بین دو طرح یکی را انتخاب نموده و در محیط نرم‌افزار Cadence با تکنولوژی ۱۸۰ نانومتر به صورت مداری شبیه‌سازی خواهد شد.


۱- طراحی مدولاتور در سطح سیستمی

در طراحی مدولاتور سیگما-دلتا، پارامترهای متعددی وجود دارند که می‌توان با استفاده از آن‌ها به مشخصات و عملکرد مطلوب دست یافت. پهنای باند مورد نظر ۵۰۰ هرتز است و دقت هدف با در نظر گرفتن تمام منابع نویز شامل نویز کوانتیزاسیون و نویز حرارتی، بالای ۱۲ بیت می‌باشد. برای دستیابی به این هدف، نسبت سیگنال به نویز و اعوجاج (SNDR) باید بیشتر یا مساوی ۷۴ دسی‌بل باشد.

¹ Schreier Toolbox


۱-۲ طراحی مدولاتور با جعبه ابزار شرایر

ساختار مدولاتور با ضرایب محاسبه شده در شکل (۱) نشان داده شده است. برای ارزیابی، لازم است این مدولاتور از نقطه نظر بهره DC و محدوده دینامیکی بررسی شود. بدیهی است که از طریق شبیه سازی محدوده دینامیکی می توان به حداکثر نسبت سیگنال به نویز کوانتیزاسیون (SQNR) نیز دست یافت.



شکل (۱): مدولاتور طراحی شده با جعبه ابزار شرایر.

نمودار محدوده دینامیکی مدولاتور در شکل (۲) نشان داده شده است. در این شبیه سازی، فرض شده است که تقویت کننده ها بهره ای برابر با ۱۰۰ دسی بل داشته باشند و ضرایب دقیقاً برابر با مقادیر نشان داده شده در شکل (۱) در نظر گرفته شده اند.



شکل (۲): محدود دینامیکی مدولاتور طراحی شده با جعبه ابزار شرایر.

همان طور که در شکل (۲) مشاهده می شود، مدولاتور حداکثر SQNR را در ورودی ۵- دسی بل تمام دامنه (dBFS) فراهم می کند. نحوه محاسبه dBFS در رابطه (۱) شرح داده شده است:


$$dBFS = 10 \times \log_{10} \frac{\text{input}}{FS \text{ input}} \quad (1)$$

طبق این رابطه، مقدار ورودی بر مقدار تمام دامنه (معمولاً ولتاژ تغذیه) تقسیم شده، سپس لگاریتم بر مبنای ۱۰ گرفته شده و نتیجه در ۲۰ ضرب می شود. برای dBFS برابر ۵-، مقدار پیک سیگنال سینوسی مطابق رابطه (۲) محاسبه می شود:

$$\frac{\text{input}}{\text{FS input}} = 10^{\frac{\text{dBFS}}{10}} \quad (2)$$

این مقدار برای dBFS برابر ۵-، معادل ۳۱۰ میلی ولت است. یعنی در صورت ولتاژ تغذیه ۱ ولت، ورودی می تواند حداکثر دامنه ۳۱۰ میلی ولت داشته باشد تا انتگرال گیرها دچار اشباع نشوند. البته در عمل، مقدار ورودی در شبیه سازی مداری باید کمتر از این مقدار باشد، زیرا اثرات غیرایده آل مداری باعث می شوند مقدار ورودی پردازش شده بیشتر از حالت ایده آل باشد.

بهره لازم برای تقویت کننده های مدار در شکل (۳) نشان داده شده است. مطابق شکل (۳)، نمودار آبی رنگ که با نمایشگرهای دایره ای مشخص شده است مربوط به تقویت کننده شماره ۱ است. این تقویت کننده همانطور که از نامش بر می آید در انتگرال گیر اول استفاده می شود. همچنین نمودار سبز رنگ که با علامت مربع نشان داده شده است مربوط به تقویت کننده شماره ۲ است که در انتگرال گیر دوم مورد استفاده قرار می گیرد.



شکل (۳): حداقل بهره لازم برای تقویت کننده های ساختار شرایر.


در این شبیه سازی، یک بهره برابر ۵۰ دسی بل فرض شده و بهره دیگر از ۱۰ تا ۸۰ دسی بل تغییر داده شده است. برای دستیابی به SQNR بالای ۹۵ دسی بل، بهره تقویت کننده ها باید از ۴۰ دسی بل بیشتر باشد. مقدار بهره بر حسب دسی بل مطابق رابطه (۳) محاسبه می شود:

$$\text{Gain (dB)} = 20 \times \log_{10} \left(\frac{V}{V'} \right) \quad (3)$$


با معکوس کردن این رابطه، بهره ۴۰ دسی بل معادل ۱۰۰ ولت بر ولت (V/V) است. با بهره کمتر از این مقدار نیز می توان به SQNR حدود ۹۰ دسی بل رسید که با توجه به دقت نهایی ۷۵ دسی بل، مقدار قابل قبولی است.

۲-۲- طراحی سیستمی ساختار پیشنهادی


طراحی و شبیه سازی ساختار پیشنهادی، در شکل (۴) نشان داده شده است. این ساختار با طراحی جعبه ابزار شرایر مقایسه شده و یکی از دو ساختار برای پیاده سازی مداری انتخاب می شود. مدولاتور پیشنهادی در شکل (۵) نشان داده شده است که حداکثر SQNR در ورودی ۵- دسی بل رخ می دهد و برابر با ۹۶ دسی بل است. در این شبیه سازی، بهره ولتاژ ۱۰۰ دسی بل فرض شده است. نتایج نشان می دهد که SQNR در این حالت نیز نزدیک به مقدار طراحی شده با جعبه ابزار شرایر است. شبیه سازی SQNR بر حسب بهره تقویت کننده در شکل (۶) ارائه شده است. برای دستیابی به SQNR بالای ۹۰ دسی بل، بهره تقویت کننده ها باید از ۴۰ دسی بل بیشتر باشد. با معکوس کردن رابطه (۳)، بهره ۴۰ دسی بل معادل ۱۰۰ ولت بر ولت است.



شکل (۴): ساختار سیستمی مدولاتور پیشنهادی.



شکل (۵): محدوده دینامیکی مدولاتور پیشنهادی.



شکل (۶): حداقل بهره لازم برای تقویت کننده های مدولاتور پیشنهادی.

۲-۳- مقایسه دو مدولاتور

مدولاتور طراحی شده با جعبه‌ابزار شرایر در مقایسه با مدولاتور پیشنهادی، مشخصات بهتری دارد. با توجه به شکل‌های (۲) و (۵)، هر دو مدولاتور تا ورودی ۵- دسی‌بل افت SQNR ندارند، اما مدولاتور شرایر در این ورودی SQNR برابر ۱۰۰ دسی‌بل دارد، در حالی که مدولاتور پیشنهادی SQNR برابر ۹۵ دسی‌بل ارائه می‌دهد.

از سوی دیگر، با در نظر گرفتن بهره محدود تقویت کننده‌ها، مدولاتور شرایر در بهره ۴۰ دسی‌بل، SQNR برابر ۹۵ دسی‌بل دارد (شکل (۳))، در حالی که مدولاتور پیشنهادی در شرایط مشابه SQNR برابر ۸۹ دسی‌بل دارد (شکل (۶)). این نشان‌دهنده کارایی بهتر مدولاتور شرایر با تقویت کننده‌های یکسان است.

در نهایت، اگر خروجی (سوئیچینگ) در شبیه‌سازی‌ها در نظر گرفته شود، مشاهده می‌شود که سوئیچینگ تمام‌تفاضلی در مدولاتور شرایر برای تقویت کننده اول برابر ± 0.6 ولت و برای تقویت کننده دوم برابر ± 0.5 ولت است. با توجه به تمام‌تفاضلی بودن ساختار و ولتاژ مرجع ± 1 ولت، خروجی تقویت کننده اول باید بین ± 0.3 ولت و تقویت کننده دوم بین ± 0.25 ولت قرار گیرد. در مدولاتورهای مرتبه پایین کم‌مصرف، معمولاً تقویت کننده‌ها یکسان در نظر گرفته می‌شوند، بنابراین حداقل سوئیچینگ ± 0.3 ولت باید برای تقویت کننده برقرار باشد. در مدولاتور شرایر، سوئیچینگ تقویت کننده اول ± 0.5 ولت و تقویت کننده دوم ± 0.2 ولت است. بنابراین مدولاتور شرایر در سوئیچینگ نیز عملکرد بهتری دارد. لازم به ذکر است که این اعداد برای ورودی ۵- دسی‌بل تمام دامنه محاسبه شده‌اند.

۲-۴- انتخاب مدولاتور

از آنجا که هر دو مدولاتور در SQNR با در نظر گرفتن بهره محدود، حدود ۶ دسی‌بل اختلاف دارند و این مقدار در SNDR تأثیر چندانی ندارد، همچنین برای حداکثر SQNR شرایط مشابهی برقرار است، تنها عاملی که می‌تواند برتری مدولاتور شرایر باشد، سوئیچینگ است که به دلیل پیچیدگی پیاده‌سازی، قابل چشم‌پوشی است. مقایسه پیاده‌سازی با جعبه‌ابزار شرایر (شکل (۱)) و پیاده‌سازی پیشنهادی (شکل (۴)) نشان می‌دهد که پیاده‌سازی مدولاتور پیشنهادی ساده‌تر و کم‌هزینه‌تر است و پیچیدگی طراحی مداری را کاهش می‌دهد.


مدولاتور پیشنهادی تعداد جمع کننده‌های کمتری دارد، در حالی که مدولاتور شرایر دارای دو جمع کننده اضافی است. مهم‌تر اینکه مدولاتور شکل (۱) ضرایب غیرمتعارف‌تری نیز دارد، به‌ویژه ضریب ۹ قبل از جمع کننده که با ضریب یک موازی شده و پیچیدگی پیاده‌سازی و تعداد خازن‌ها را افزایش می‌دهد. بنابراین، با وجود پارامترهای بهتر مدولاتور شرایر، به دلیل سادگی پارامترهای مدولاتور نهایی و پیچیدگی پیاده‌سازی مدولاتور شرایر، ساختار پیشنهادی برای پیاده‌سازی انتخاب شده است.

۳- طراحی و شبیه‌سازی مدار مدولاتور

۳-۱- طراحی و پیاده‌سازی مدار تقویت کننده

نخستین عنصر مورد بررسی، تقویت کننده ترانسانایی (OTA) است که نقش بسیار مهمی در مدولاتور دارد، زیرا کاملاً آنالوگ بوده و وظیفه تغذیه بخشی از خازن‌های مدار را بر عهده دارد. این عنصر بیشترین توان مصرفی مدار را به خود اختصاص می‌دهد [۷]، [۸] و طراحی دقیق آن ضروری است. در این مقاله از تقویت کننده دوطبقه با جبران‌سازی توسط خازن بار استفاده شده است که سوئیچینگ بسیار خوبی داشته و از نظر توان مصرفی نسبت به سایر ساختارها با در نظر گرفتن سرعت و توان درایو یکسان، بهینه است.

در این تقویت کننده، قطب غالب توسط خازن بار و مقاومت خروجی طبقه اول تعیین می شود. با توجه به کم مصرف بودن مدار، بایاس جریان ترانزیستورها روی مقادیر کم تنظیم می شود؛ بنابراین مقاومت بین درین و سورس ترانزیستورها زیاد شده و قطب به فرکانس های پایین تر سوق می یابد که باعث بهبود حاشیه فاز نیز می شود. بدین ترتیب می توان با خازن کمتر، قطب غالب را ایجاد کرد که خود باعث کاهش توان می شود، به ویژه اینکه با کاهش جریان، عمل جبران سازی بهتر انجام شده و این دو در جهت هماهنگی حرکت می کنند که باعث کاهش جریان مصرفی و در نهایت توان مصرفی تقویت کننده می شود.




شکل (۷): شماتیک تقویت کننده دو طبقه با جبران سازی خازن بار.


ترانزیستورهای M5 و M5b نقش تقویت کننده طبقه دوم را ایفا می کنند. ترانزیستورهای M6 و M6b برای تنظیم فیدبک مد مشترک طبقه خروجی به کار رفته اند و ترانزیستورهای M7 و M7b نقش بار این طبقه را بر عهده دارند. شبیه سازی مدار با نرم افزار Cadence و تکنولوژی ۱۸۰ نانومتر انجام شده است.

مدار با خازن بار خروجی ۲ پیکوفاراد شبیه سازی شده است. شبیه سازی نهایی در حالت AC برای سنجش بهره، پهنای باند و حاشیه فاز انجام شده است. مطابق شکل (۸)، بهره DC برابر ۴۰ دسی بل، پهنای باند بهره واحد برابر ۷ مگاهرتز و حاشیه فاز برابر ۷۰ درجه است. با توجه به نسبت نمونه برداری اضافی (OSR) برابر ۲۵۶ و فرکانس نایکوئیست ۱ کیلوهرتز، مدولاتور باید در فرکانس ۲۵۶ کیلوهرتز کار کند و پهنای باند ۷ مگاهرتز بیش از ده برابر فرکانس مذکور است، بنابراین از نظر نشست مدار مشکلی وجود نخواهد داشت.

شبیه سازی برای خازن بار ۴ پیکوفاراد نیز انجام شده است (شکل (۹)). در این حالت، بهره DC برابر ۴۰ دسی بل، پهنای باند بهره واحد برابر ۳/۷ مگاهرتز و حاشیه فاز برابر ۸۰ درجه است که نسبت به حالت قبل بهتر است. تقویت کننده توانی برابر ۵/۲۶ میکرووات مصرف می کند.



شکل (۸): نمودار بهره و فاز تقویت کننده بر حسب فرکانس برای خازن بار ۲ پیکوفاراد.



شکل (۹): نمودار بهره و فاز تقویت کننده بر حسب فرکانس برای خازن بار ۴ پیکوفاراد.


۲-۳- طراحی مدار مقایسه گر

اگرچه مدولاتور سیگما-دلتا دقت بالایی دارد، ولی با وجود شکل دهی نویز و بیش نمونه برداری، کوانتایزر در این مدولاتور بسیار ساده پیاده سازی می شود. بنابراین مقایسه گر ها که عنصر اصلی کوانتایزر هستند، نیازی به پیچیدگی ندارند. در این مقاله از مقایسه گر مرجع [۹] استفاده شده است که در شکل (۱۰) نشان داده شده است. به دلیل یک بیتی بودن کوانتایزر، تنها یک مقایسه گر در مدار استفاده می شود.


در این مقایسه گر، زمانی که سیگنال کلاک صفر است، گره های X و Y به ولتاژ تغذیه تنظیم می شوند و اثر حافظه بیت های قبلی حذف می گردد. با انتقال کلاک از صفر به یک، گره های شارژ شده توسط ترانزیستورهای M1a و M1b شروع به دشارژ به زمین

۳-۳- شیه‌سازی مدولاتور

مقدار SNDR با احتساب نویز حرارتی در شکل (۱۲) برای ورودی ۵- دسی بل تمام دامنه نشان داده شده است. با داشتن دامنه‌های مختلف ورودی، محدوده دینامیکی مدولاتور در شکل (۱۳) ترسیم شده است.



شکل (۱۲): طیف خروجی مدولاتور با ورودی ۵- دسی بل تمام دامنه.



شکل (۱۳): منحنی محدوده دینامیکی مدولاتور در شبیه سازی مدار.

توان مصرفی مدولاتور برابر ۱۰/۷ میکرووات است که حدود ۰/۳ میکرووات توسط مقایسه گر و مابقی توسط دو تقویت کننده مصرف می شود. با در نظر گرفتن SNDR برابر ۷۶/۳ دسی بل، تعداد بیت های مؤثر (ENOB) برابر ۱۲/۴ است. با در نظر گرفتن پهنای باند ۵۰۰ هرتز، ضریب شایستگی مطابق رابطه (۴) محاسبه می شود:


$$FoM = \frac{Power}{2 \times BW \times 2^{ENOB}} = \frac{10.7 \times 10^{-6}}{2 \times 500 \times 2^{12.4}} = 1.98 \times 10^{-12} \frac{J}{Cov - Step} \quad (4)$$

که در آن Power بر حسب وات، ENOB بر حسب بیت و BW بر حسب هرتز است. مقدار FOM برابر ۱/۹۸ پیکوژول بر سطح تبدیل به دست می آید که نشان دهنده کارایی خوب مدار در مقایسه با طراحی های مشابه در جدول (۱) است.

به منظور توصیف دقیق تر رفتار حوزه فرکانس مدولاتور سیگما-دلتای مرتبه دوم پیشنهادی، تابع انتقال سیگنال (STF) و تابع انتقال نویز (NTF) بررسی شدند. برای حلقه ایده آل شکل دهی نویز مرتبه دوم، تابع انتقال سیگنال و نویز را می توان به صورت رابطه ۵ بیان کرد:

$$STF(z) \approx z^{-2}, NTF(z) = (1 - z^{-1})^2 \quad (5)$$

این رابطه نشان دهنده سرکوب نویز کوانتیزاسیون در فرکانس های پایین به میزان متناظر با شکل دهی نویز مرتبه دوم و انتقال آن به سمت فرکانس های بالاتر است. با در نظر گرفتن پهنای باند سیگنال برابر با ۵۰۰ هرتز و فرکانس نمونه برداری ۲۵۶ کیلوهرتز در مدار پیشنهادی، نویز کوانتیزاسیون شکل دهی شده عمدتاً به خارج از باند سیگنال منتقل می شود.



شکل (۱۴): انتقال سیگنال (STF) و انتقال نویز (NTF) مدولاتور سیگما-دلتا مرتبه دوم.

جدول (۱): مقایسه مدولاتورها [14]

مشخصات	این مقاله	۲۰۱۳[14]	۲۰۰۹[13]	۲۰۱۰[12]	۲۰۰۶[11]	۲۰۱۰[10]	۲۰۰۸[8]
ولتاژ تغذیه (V)	۱/۲	۱	۱	۱	۰/۹	۰/۸	۰/۹
پهنای باند (kHz)	۰/۵	۱۰	۱۶	۲۰	۱۰	۰/۲۵	۲۰
SNDR (dB)	۷۶/۳	۶۴/۸	۵۸	۸۴	۸۰/۱	۴۸/۲	۷۳
توان مصرفی (μW)	۱۰/۷	۱۷/۱	۱۸/۱	۶۶۰	۲۰۰	۰/۸۱	۶۰
تکنولوژی (μm)	۰/۱۸	۰/۰۹	۰/۱۸	۰/۱۸	۰/۱۸	۰/۱۸	۰/۱۳
FOM (pJ/conv.)	۱/۹۸	۰/۶	۰/۸۷	۹۲/۹	۱/۲۱	۷/۷۷	۰/۴۱

۴- نتیجه گیری

در این مقاله، طراحی در سطح سیستمی با مدولاتور مرتبه دوم با استفاده از جعبه ابزار شرایر و مقایسه با مدولاتور پیشنهادی انجام شد. از بین دو طرح، به دلیل سادگی پارامترها و کاهش پیچیدگی پیاده سازی، مدولاتور پیشنهادی برای پیاده سازی مدارای انتخاب گردید. در طرح مدارای، تقویت کننده دوطبقه با سوئیچینگ مناسب و توان کم طراحی شد. شبیه سازی مدارای مدولاتور سیگما-دلتا با حداکثر SNDR برابر ۷۶/۳ دسی بل، تعداد بیت های مؤثر ۱۲/۴ و پهنای باند ۵۰۰ هرتز برای کاربردهای مهندسی پزشکی به انجام رسید. توان مصرفی کل مدولاتور برابر ۱۰/۷ میکرووات است که از نظر کارایی انرژی، عملکرد بهتری نسبت به بسیاری از مدولاتورهای مشابه دارد. ضریب شایستگی ۱/۹۸ پیکوژول بر سطح تبدیل، نشان دهنده مناسب بودن این ساختار برای سیستم های پزشکی قابل کاشت و کم مصرف است. نتایج این پژوهش با مطالعات پیشین نویسندگان در زمینه طراحی مدولاتورهای سیگما-دلتا با توان پایین همخوانی دارد [۱۵، ۱۶].

مراجع

1. H. Inose, Y. Yasuda, and J. Murakami, "A Telemetry System by Code Modulation: Δ - Σ Modulation," IRE Trans. Space Electron. Telemetry, vol. SET-8, pp. 204-209, Sep. 1962.
2. L. S. Y. Wong et al., "A Very Low-Power CMOS Mixed-Signal IC for Implantable Pacemaker Applications," IEEE J. Solid-State Circuits, vol. 39, no. 12, pp. 2446-2456, Dec. 2004.
3. Y. Chae and G. Han, "Low Voltage, Low Power, Inverter-Based Switched-Capacitor Delta-Sigma Modulator," IEEE J. Solid-State Circuits, vol. 44, no. 2, pp. 458-472, Feb. 2009.
4. J. Goes et al., "Low-Power Low-Voltage CMOS A/D Sigma-Delta Modulator for Bio-Potential Signals Driven by a Single-Phase Scheme," IEEE Trans. Circuits Syst. I, vol. 52, no. 12, pp. 2595-2604, Dec. 2005.
5. S. A. Zanjani, A. Jannesari, and P. Torkzadeh, "9.9 μ W, 140 dB DR, and 93.27 dB SNDR, Double Sampling $\Delta\Sigma$ Modulator Using High Swing Inverter-Based Amplifier for Digital Hearing Aids," Electronics, vol. 12, no. 7, p. 1747, 2023.
6. R. Schreier, "Delta-Sigma Toolbox for MATLAB," 2000. [Online]. Available: <http://www.mathworks.com/matlabcentral/fileexchange/19-delta-sigma-toolbox>
7. L. Yao, M. Steyaert, and W. Sansen, "A 1-V 140- μ W 88-dB Audio Sigma-Delta Modulator in 90-nm CMOS," IEEE J. Solid-State Circuits, vol. 39, no. 11, pp. 1809-1818, Nov. 2004.
8. J. Roh, S. Byun, Y. Choi, H. Roh, Y. G. Kim, and J. K. Kwon, "A 0.9-V 60- μ W 1-bit Fourth-Order Delta-Sigma Modulator With 83-dB Dynamic Range," IEEE J. Solid-State Circuits, vol. 43, no. 2, pp. 361-370, Feb. 2008.
9. T. B. Cho and P. R. Gray, "A 10 b, 20 Msample/s, 35 mW Pipeline A/D Converter," IEEE J. Solid-State Circuits, vol. SC-30, pp. 166-172, Mar. 1995.
10. H. Roh, H. Lee, and Y. Choi, "A 0.8-V 816-nW Delta-Sigma Modulator for Low-Power Biomedical Applications," Analog Integr. Circuits Signal Process., vol. 63, no. 1, pp. 101-106, 2010.
11. J. Goes, B. Vaz, R. Monteiro, and N. Paulino, "A 0.9 V $\Delta\Sigma$ modulator with 80 dB SNDR and 83 dB DR using a single-phase technique," in Proc. IEEE Int. Solid-State Circuits Conf. (ISSCC), Feb. 2006, pp. 74-75.
12. C.-H. Kuo, D.-Y. Shi, and K.-S. Chanag, "A Low-Voltage Fourth-Order Cascade Delta-Sigma Modulator in 0.18- μ m CMOS," IEEE Trans. Circuits Syst. I, vol. 57, no. 9, Sep. 2010.
13. P.-H. Su and H. Chiueh, "The Design of Low-Power CIFF Structure Second-Order Sigma-Delta Modulator," in Proc. 52nd IEEE Int. Midwest Symp. Circuits Syst. (MWSCAS), Aug. 2009, pp. 377-380.
14. C.-H. Hsu and K.-T. Tang, "A 1V low power second-order delta-sigma modulator for biomedical signal application," in Proc. 35th Annu. Int. Conf. IEEE Eng. Med. Biol. Soc. (EMBC), Jul. 2013, pp. 1520-1523.
15. M. R. Farsi and K. Monfaredi, "Design and Simulation of High Precision Second-Order Sigma-Delta Modulator for Bluetooth Applications," J. Eng. Sci. Technol., vol. 13, no. 10, pp. 3073-3088, Oct. 2018.

16. M. R. Farsi and K. Monfaredi, "Design of a High-Precision Second-Order Sigma-Delta Modulator with Low Power Consumption for Medical Applications," *Journal of Modeling in Engineering (JME)*, vol. 16, no. 55, pp. 191-197, 2018. DOI: 10.22075/jme.2018.12865.1263.



Sahand University
of Technology

DOR:

[20.1001.1.23223146.1405.12.2.5.4](https://doi.org/10.1001.1.23223146.1405.12.2.5.4)

**Journal of Nonlinear
Systems in Electrical
Engineering**

Vol. 12, No. 2

Autumn and Winter 2025

ISSN: 2322 – 3146

<http://jnsee.sut.ac.ir>

Robust Adaptive Fuzzy Sliding Mode Control for Synchronization of Unknown Noncanonical Chaotic Systems

Mohammad Safari Souri, Seyed Kamaledin Mousavi Mashhadi, Mohammad Fiuzy*

Control Department, School of Electrical Engineering, Iran University of Science and Technology

* Corresponding author email: mohammad.fiuzy@yahoo.com

Abstract

This paper presents the design and implementation of a robust adaptive fuzzy sliding mode controller for the synchronization of non-canonical chaotic systems. Unlike most conventional approaches reported in the literature, the system dynamics are assumed to be completely unknown, and no prior information or bounds on uncertainties, external disturbances, or unknown parameters are required. The proposed control strategy employs an Adaptive Neuro-Fuzzy Inference System (ANFIS) to approximate and identify the unknown chaotic system dynamics in an online manner. Subsequently, a sliding mode control law is developed to ensure accurate and stable synchronization between the drive and response systems. To rigorously analyze the closed-loop behavior, the asymptotic stability of the overall system and the convergence of the synchronization error are mathematically guaranteed using Lyapunov stability theory. Numerical simulation results conducted on the Lorenz and Chen chaotic systems demonstrate the effectiveness, high accuracy, and strong robustness of the proposed method in the presence of external disturbances and unbounded uncertainties, highlighting its potential for practical engineering applications.

Keywords

Chaos synchronization; Robust adaptive sliding mode control; Adaptive neuro-fuzzy inference system (ANFIS); Non-canonical chaotic systems; Lyapunov stability; Unbounded uncertainties

1. Short Introduction

Chaos theory has attracted significant attention due to the complex and unpredictable behavior of nonlinear chaotic systems. Synchronization of chaotic systems, first introduced by Carroll and Pecora, has become essential in various engineering applications, with numerous methods such as sliding mode control, adaptive control, and fuzzy control proposed in the literature. Despite these advances, many existing approaches assume bounded uncertainties or fully known system dynamics. This paper proposes a robust adaptive fuzzy sliding mode control strategy capable of synchronizing chaotic systems in the presence of external disturbances and unbounded uncertainties. The effectiveness of the method is validated through several simulation examples involving different chaotic systems.

2. Proposed Work

This study introduces an adaptive fuzzy sliding mode control strategy for synchronizing chaotic systems under external disturbances and unbounded uncertainties. The controller design integrates multiple linear sliding surfaces with an adaptive switching law, while an adaptive neuro-fuzzy network is employed to identify unknown nonlinearities without requiring prior bounds. Stability of the synchronization scheme is rigorously proven using Lyapunov theory, ensuring asymptotic convergence of the synchronization error. To demonstrate the effectiveness and robustness of the proposed method, three simulation scenarios are conducted: synchronization of the Chen system with different initial conditions, synchronization of the Lorenz system with different initial conditions, and cross-synchronization between the Chen and Lorenz systems. The results confirm that the proposed controller achieves fast convergence, strong robustness against disturbances, and superior performance compared to conventional sliding mode approaches.

3. Conclusion

This paper introduced a novel adaptive fuzzy sliding mode control approach for synchronizing non-canonical chaotic systems under uncertainties and disturbances. The stability of the proposed method was rigorously established through Lyapunov theory, and the adaptive neuro-fuzzy structure successfully estimated unknown system parameters. Using adaptive rules, the required control input for achieving synchronization was derived. Numerical simulations involving Chen–Chen, Lorenz–Lorenz, and Chen–Lorenz synchronization scenarios confirmed the robustness and effectiveness of the proposed strategy.

سنکرون سازی سیستم های آشوبناک غیر کانونیکال نامعلوم با استفاده از کنترل مود لغزشی تطبیقی-فازی مقاوم

محمد صفری سوری، سید کمال الدین موسوی مشهدی، محمد فیوضی*

گروه کنترل، دانشکده مهندسی برق، دانشگاه علم و صنعت ایران

* آدرس پست الکترونیکی نویسنده مسئول: mohammad.fiuzy@yahoo.com



دانشگاه صنعتی شاهرود

DOR:

[20.1001.1.23223146.1405.12.2.5.4](https://doi.org/10.1001.1.23223146.1405.12.2.5.4)

نشریه علمی-فصلنامه «مهندسی برق»

دوره ۱۲ - شماره ۲

پاییز و زمستان ۱۴۰۴

صفحات ۸۷ الی ۱۰۸

ISSN: 2322-3146

<http://jnsee.sut.ac.ir>

تاریخ پذیرش: ۱۴۰۵/۶/۹

تاریخ بازنگری: ۱۴۰۵/۵/۲۷

تاریخ ارسال: ۱۴۰۴/۱۱/۸

چکیده

واژه های کلیدی

سنکرون سازی آشوب

کنترل مود لغزشی تطبیقی

سیستم استنتاج عصبی-فازی

سیستم های غیر کانونیکال

پایداری لیاپانوف

نامعینی نامحدود

این مقاله به طراحی و پیاده سازی یک کنترل کننده مود لغزشی تطبیقی-فازی مقاوم برای سنکرون سازی سیستم های آشوبناک غیر کانونیکال می پردازد. برخلاف اغلب رویکردهای سنتی در ادبیات کنترل، در این پژوهش اگرچه دینامیک سیستم نامعلوم فرض شده، اما عدم قطعیت ها، اغتشاشات خارجی و پارامترهای ناشناخته همگی کران دار در نظر گرفته شده اند. راهبرد کنترلی پیشنهادی با بهره گیری از سیستم استنتاج عصبی-فازی تطبیقی ابتدا به تقریب و شناسایی برخط مدل سیستم آشوبناک پرداخته و سپس با اعمال قوانین کنترلی مود لغزشی، سنکرون سازی دقیق و پایدار میان سیستم های مرجع و پاسخ را تضمین می کند. همچنین پایداری مجانبی سیستم حلقه بسته و همگرایی خطای سنکرون سازی بر اساس تئوری پایداری لیاپانوف به صورت ریاضی اثبات شده است. در نهایت، شبیه سازی های عددی بر روی سیستم های آشوبناک لورنز و چن، عملکرد مطلوب، دقت بالا و مقاوم بودن روش پیشنهادی را در حضور اغتشاشات و عدم قطعیت ها تأیید می کنند.

۱- مقدمه

تئوری آشوب و بررسی رفتار سیستم های دینامیکی غیرخطی پیچیده از موضوعات بنیادین و پر کاربرد در حوزه مهندسی و علوم پایه است. از زمان معرفی اولین سیستم آشوبناک توسط لورنز [۱] و توسعه سیستم های غیرخطی بعدی [۴-۲] مسئله کنترل و دستکاری رفتار آشوبی به یکی از زمینه های جذاب پژوهشی تبدیل شده است. در این میان، سنکرون سازی سیستم های آشوبناک به دلیل نقش کلیدی آن در حوزه های متنوعی همچون مهندسی شیمی [۵]، پردازش اطلاعات [۶] و مخابرات امن [۷، ۸] اهمیت مضاعفی یافته است. مفهوم سنکرون سازی نخستین بار توسط کارول و پکورا [۹] مطرح شد که هدف آن همگام سازی پاسخ سیستم پیرو (Slave) با سیستم مرجع (Master) است. با این حال، ویژگی های ذاتی سیستم های آشوبناک مانند حساسیت شدید به شرایط اولیه و وابستگی بالا به پارامترهای مدل، طراحی روش های سنکرون سازی مقاوم و دقیق را با چالش های اساسی مواجه می سازد [۱۰].

برای غلبه بر این چالش ها، روش های کنترلی متعددی از جمله کنترل تطبیقی [۱۱]، کنترل فازی [۱۲، ۱۳]، مشاهده گرهای حالت [۱۴، ۱۵] و کنترل پیش بین [۱۶] پیشنهاد شده اند. در این میان، کنترل مود لغزشی (SMC) به دلیل سادگی در پیاده سازی و مقاومت ذاتی در برابر نامعینی ها و اغتشاشات، جایگاه ویژه ای در سنکرون سازی سیستم های غیرخطی یافته است [۲۰-۱۷]. با وجود این مزایا، کنترل مود لغزشی کلاسیک با دو محدودیت ساختاری عمده روبه رو است: پدیده نوسانات شدید یا چترینگ (Chattering) ناشی از توابع ناپیوسته سوئیچینگ [۲۱]، و نیاز به دانستن کران بالایی عدم قطعیت ها و اغتشاشات خارجی جهت تنظیم ضرایب کنترلی.

مرور کارهای گذشته نشان می دهد که اکثر روش های ارائه شده برای سنکرون سازی، یا کارایی آن ها منوط به محدود بودن و مشخص بودن کران عدم قطعیت ها است [۲۲، ۲۳] و یا سیستم را کاملاً معین فرض کرده اند [۲۴]. همچنین در برخی پژوهش ها برای کاهش چترینگ از سیستم های فازی استفاده شده اما دامنه فرضیات مسئله به کلاس خاصی از سیستم ها (مانند سیستم های کانونیکال مرتبه دوم) محدود گردیده است [۲۶-۲۴]. در کاربردهای واقعی، تعیین کران دقیق عدم قطعیت ها و اغتشاشات ناممکن است و بزرگ در نظر گرفتن تخمینی این کران ها، موجب تشدید شدید پدیده چترینگ و فشار به عملگرها می شود.

با توجه به شکاف های تحقیقاتی فوق، انگیزه اصلی این مقاله ارائه یک راهبرد کنترلی جامع، مقاوم و بدون نیاز به اطلاعات پیشین از کران عدم قطعیت ها است. در این راستا، یک کنترل کننده مود لغزشی تطبیقی-فازی مبتنی بر شبکه عصبی-فازی تطبیقی (ANFIS) برای سنکرون سازی سیستم های آشوبناک در حضور اغتشاشات خارجی و عدم قطعیت های با کران ناشناخته طراحی می شود.

نوآوری ها و ویژگی های برجسته روش پیشنهادی عبارتند از:

تخمین برخط عدم قطعیت ها: استفاده از شبکه عصبی-فازی تطبیقی جهت تقریب دقیق و برخط عدم قطعیت های سیستم بدون نیاز به دانستن کران بالایی آن ها.

حذف پدیده چترینگ: بهره گیری از قوانین سوئیچینگ تطبیقی و ترکیب آن با ساختار فازی به منظور هموار سازی سیگنال کنترلی.

تضمین پایداری ریاضی: اثبات پایداری مجانبی و همگرایی خطای سنکرون سازی به صفر بر اساس تئوری پایداری لیاپانوف.

ادامه این مقاله به شرح زیر سازمان دهی شده است: در بخش ۲، مفاهیم پایه و ساختار شبکه ANFIS مرور می شود. در بخش ۳، مدل سازی مسئله، فرضیات و مراحل طراحی کنترل کننده به همراه اثبات ریاضی پایداری ارائه می گردد. در بخش ۴، جهت ارزیابی کارایی روش پیشنهادی، شبیه سازی های عددی بر روی سیستم های آشوبناک لورنز و چن (در حالت های شرایط اولیه متفاوت و سیستم های ناهمسان) انجام می پذیرد. در نهایت، بخش ۵ به جمع بندی و ارائه نتایج اختصاص یافته است.

۲- مقدمات

در این بخش، مروری مختصر بر مبانی شبکه های عصبی تطبیقی-فازی ارائه می شود که مطالب آن با بهره گیری از مباحث ارائه شده در مراجع [۲۷-۳۱] تدوین شده است. سیستم های فازی و سیستم های عصبی هر کدام به نوبه خود دارای نواقصی هستند. سیستم های استنتاج فازی با توجه توانایی استفاده از تجربیات فرد خبره، می توانند در کنترل حالت های مختلف یک سیستم کنترلی مورد استفاده قرار گیرند. اما به دلیل عدم توانایی تغییر توابع عضویت ورودی و خروجی، نمی توانند با استفاده از داده های ورودی و خروجی تغییراتی را در توابع عضویت ایجاد کنند که موجب بهبود عملکرد کنترلی شود. در عوض شبکه های عصبی نیز توانایی استفاده از قواعد زبانی را ندارند، از این رو این سیستم ها نیز انعطاف لازم را برای استفاده در سیستم های کنترلی ندارند. سیستم استنتاج عصبی تطبیقی-فازی نوعی شبکه مصنوعی است که بر اساس سیستم فازی تاکاگی-سوگنو است. این سیستم قابلیت یادگیری برای تقریب زدن توابع غیر خطی را دارد. سیستم استنتاج عصبی تطبیقی-فازی بر پایه مجموعه ای از قواعد اگر-آنگاه زبانی عمل می کند. گره های تطبیقی موجود در شکل ۱ دارای پارامترهایی هستند که توسط الگوریتم یادگیری به گونه ای تنظیم می شوند که شبکه عصبی تطبیقی-فازی بتواند رفتار توابع غیر خطی را با دقت مورد نظر تعیین کند. برای یک سیستم استنتاج فازی تاکاگی-سوگنو یک قانون اگر-آنگاه فازی برای شبکه های استنتاج عصبی تطبیقی-فازی به صورت زیر بیان می شود:

$$R^{(l)}: IF \quad x_1 \text{ is } A_{1l}, \text{ and...and } x_n \text{ is } A_{nl}, THEN \quad y_l = p_{0l} + p_{1l}x_1 + \dots + p_{nl}x_n = \underline{\theta}_l^T \begin{bmatrix} 1 & \underline{x}^T \end{bmatrix}^T \quad (1)$$

که A_{il} مجموعه های فازی و $\underline{\theta}_l^T = [p_{0l} \quad p_{1l} \quad \dots \quad p_{nl}]$ بردار ضرایب قابل تنظیم قانون فازی است که توسط قواعد تطبیقی تنظیم می شود. y_l متغیر زبانی خروجی است موتور استنتاج فازی از ترکیب قواعد اگر-آنگاه موجود در پایگاه قواعد، متغیرهای زبانی ورودی $\underline{x}^T = [x_1, x_2, \dots, x_n]$ را به آن نگاشت می دهد. باید توجه کرد که برای سیستم تاکاگی-سوگنو $x_i, y_i \in \square \quad i = 1, \dots, n$ است. در صورتی که تعداد قواعد اگر-آنگاه فازی برابر M فرض شود برای غیر فازی سازی سیستم فازی با استفاده از غیر فازی کننده میانگین مرکزی داریم:

$$y(x) = \frac{\sum_{l=1}^M v_l \cdot y_l}{\sum_{l=1}^M v_l} = \frac{\sum_{l=1}^M v_l \cdot \underline{\theta}_l^T \begin{bmatrix} 1 & \underline{x}^T \end{bmatrix}^T}{\sum_{l=1}^M v_l} \quad (2)$$


که $v_l = \prod_{i=1}^n \mu_{A_{il}}(x_i)$ مقدار درستی l امین قاعده اگر-آنگاه است و $\mu_{A_{il}}(x_i)$ برابر مقدار تابع عضویت متغیر x_i است. رابطه (۲) را می توان به صورت زیر نیز بیان کرد:

$$y(x) = \underline{\theta}^T \phi(x) \quad (۳)$$

که $\underline{\theta}^T = [\underline{\theta}_1^T \quad \underline{\theta}_2^T \quad \dots \quad \underline{\theta}_M^T]$ پارامترهای قابل تنظیم و $\phi^T(\underline{x}) = [\phi_1(\underline{x}) \quad \phi_2(\underline{x}) \quad \dots \quad \phi_M(\underline{x})]$ تابع فازی اصلی است و به صورت زیر تعریف می شود:

$$\phi_l(\underline{x}) = \frac{v_l \cdot [1 \quad \underline{x}^T]^T}{\sum_{l=1}^M v_l} \quad (۴)$$

سیستم فازی رابطه (۲) یک تقریب زننده ی عمومی برای توابع غیر خطی خوش رفتار است [۳۲] و می تواند دینامیک های ناشناخته ی سیستم های آشوبناک را بر اساس داده های ورودی-خروجی با دقت بالا تخمین بزند. ساختار این تقریب زننده، که در طراحی کنترل کننده مورد استفاده قرار می گیرد، در قالب شبکه ی عصبی-فازی تاکاگی-سوگنو در شکل ۱ نمایش داده شده است.



شکل ۱: بلوک دیاگرام شبکه عصبی تطبیقی-فازی

۳- سنکرون سازی سیستم های آشوبناک غیر کانونیکال با استفاده از روش کنترل مود

لغزشی تطبیقی-فازی

به منظور سنکرون سازی سیستم های آشوبناک یک سیستم به عنوان سیستم مرجع و یک سیستم به عنوان سیستم پیرو در نظر گرفته می شود. هدف از این روش این است که ورودی کنترلی به گونه ای تعیین شود تا سیستم پیرو رفتار مشابه سیستم مرجع را از خود ارائه دهد. سیستم آشوبناک غیر کانونیکال زیر را به عنوان سیستم مرجع در نظر بگیرید:

$$\dot{x}(t) = f(x, t) \quad (5)$$

که $x(t) = [x_1(t) \ \cdots \ x_n(t)]^T$ و همچنین داریم که $f(x, t) = [f_1(x, t) \ \cdots \ f_n(x, t)]^T$ است. معادلات سیستم پیرو به صورت زیر در نظر گرفته می شود:

$$\dot{y}(t) = g(y, t) + u(t) + d(t) \quad (6)$$

که $y(t) = [y_1(t) \ \cdots \ y_n(t)]^T$ و $g(y, t) = [g_1(y, t) \ \cdots \ g_n(y, t)]^T$ و $u(t) = [u_1(t) \ \cdots \ u_n(t)]^T$ ورودی کنترلی در نظر گرفته شده و $d(t) = [d_1(t) \ \cdots \ d_n(t)]^T$ اغتشاش محدود است. خطا را به صورت زیر تعریف می کنیم:

$$e(t) = y(t) - x(t) \quad (7)$$

دینامیک خطا برابر است با:

$$\dot{e}(t) = g(y, t) + d(t) + u(t) - f(x, t) \quad (8)$$

در رابطه (۸)، $f(x, t)$ و $g(y, t)$ دو تابع غیر خطی و نامعلوم اما محدود هستند، در حقیقت، فرض می شود که توابع نامعلوم $f(x, t)$ و $g(y, t)$ روی ناحیه ی کاری سیستم، یعنی مجموعه ی کراندار Ω_x ، دارای کران بالا هستند. به صورت دقیق، تابع f محدود است اگر عدد مثبتی مانند M_f وجود داشته باشد به طوری که $|f(x, t)| \leq M_f \ \forall x \in \Omega_x$ به طور مشابه، تابع g محدود است اگر $|g(x, t)| \leq M_g \ \forall x \in \Omega_x$. از آنجا که دینامیک های سیستم های آشوبناک چن و لورنز پیوسته هستند و مسیر حالت ها در تمامی شبیه سازی ها در یک ناحیه ی کراندار قرار می گیرند، توابع نامعلوم f و g نیز روی این ناحیه محدود خواهند بود. این ویژگی امکان استفاده از تقریب زننده ی عصبی-فازی و تضمین پایداری لیاپانوف را فراهم می کند. در صورتی که صفحات لغزشی را به صورت:

$$S_i(t) = k_i e_i(t), \quad i = 1, \dots, n \quad (9)$$

در نظر بگیریم، برای کنترل سیستم با استفاده از روش مود لغزشی می بایست از چند سطح لغزشی استفاده کرد. کنترل مود لغزشی به دو فاز تقسیم می شود. زمانی که $S_i(t) = 0$ و در فاز لغزشی^۱ هستیم و زمانی که $S_i(t) \neq 0$ یعنی در فاز رسیدن^۲ هستیم. در صورتی که در فاز رسیدن باشیم باید $\dot{S}_i(t) = 0$ باشد.

$$\dot{S}_i(t) = k_i \dot{e}_i(t), \quad i = 1, \dots, n \quad (10)$$

با جایگذاری (۸) در (۱۰) داریم:

$$\dot{S}_i(t) = k_i (g_i(y, t) - f_i(x, t) + u_i(t) + d_i(t)) = 0 \quad (11)$$

در نتیجه با توجه به رابطه (۱۱) نیروی کنترلی معادل برابر است با:

$$u_{eq,i}(t) = f_i(x, t) - g_i(y, t) + d_i(t), \quad i = 1, \dots, n \quad (12)$$

و همچنین شرط کافی برای تضمین این که خطای سنکرون سازی، از فاز رسیدن به فاز لغزشی برسد برابر است با:

$$S_i(t) \dot{S}_i(t) \leq -\eta_i |S_i(t)| \leq 0, \quad i = 1, \dots, n \quad (13)$$

به منظور این که شرط لغزشی علیرغم عدم قطعیت در دینامیک g_i برقرار بوده و بر روی $S_i = 0$ باقی بماند باید یک جمله ناپیوسته به کنترل معادل اضافه شود، از این رو رابطه (۱۲) برابر است با:

$$u_i(t) = f_i(x, t) - g_i(y, t) - \eta_i \text{sign}(S_i(t)), \quad i = 1, \dots, n \quad (14)$$

که η_i یک ثابت مثبت است که شرط رسیدن به حالت لغزشی را تضمین می کند و برای تضمین شرط رسیدن داریم:

$$\eta_i > |d_i(t)| + |\omega_i(t)|, \quad i = 1, \dots, n \quad (15)$$

که ω_i حداقل خطای تخمین است. می دانیم که توابع $f_i(x, t)$ و $g_i(y, t)$ تابعی نامعلوم هستند و باید توسط سیستم های استنتاج فازی جایگزین شوند:

$$f_i(x | \underline{\theta}_{f_i}) = \underline{\theta}_{f_i}^T \underline{\xi}_i(x), \quad i = 1, \dots, n \quad (16)$$

$$g_i(y | \underline{\theta}_{g_i}) = \underline{\theta}_{g_i}^T \underline{\xi}_i(y), \quad i = 1, \dots, n \quad (17)$$

که $\underline{\theta}_{g_i}^T$ و $\underline{\theta}_{f_i}^T$ ضرایب قابل تنظیم توسط سیستم استنتاج فازی هستند. پس ورودی کنترلی برابر است با:

¹ Sliding Phase

² Reaching Phase

$$u_i(t) = f_i(x | \underline{\theta}_{f_i}) - g_i(y | \underline{\theta}_{g_i}) - \eta_i \text{sign}(S_i(t)), \quad i = 1, \dots, n \quad (18)$$

قضیه: در صورتی که معادلات حالت یک سیستم آشوبناک به صورت غیر کانونیکال و معادل با معادله (۶) باشد که در اینجا $g(y, t)$ برداری از توابع نامعلوم و $d(t)$ بردار اغتشاش ورودی و محدود است، آنگاه می توان پاسخ خروجی این سیستم را با یک ورودی کنترلی مشابه (۱۸) به سیستم با معادله (۵) رساند که $f(x, t)$ برداری از توابع نامعلوم است. که توابع $f(x, t)$ و $g(y, t)$ توسط سیستم عصبی تطبیقی-فازی تخمین زده می شوند. این همگرایی به ازای هر $i = 1, \dots, n$ با شرایط:

$$\frac{d\tilde{\theta}_{f_i}}{dt} = a_i S_i(t) \xi_i(x), \quad a_i > 0 \quad (19)$$

$$\frac{d\tilde{\theta}_{g_i}}{dt} = -b_i S_i(t) \xi_i(y), \quad b_i > 0 \quad (20)$$

امکان پذیر است، که a_i و b_i پارامترهای اختیاری هستند که توسط طراح تنظیم می شوند. شرایط (۱۹) و (۲۰) پایدارمجبانی بودن روش پیشنهادی را تضمین می کنند.

اثبات: در ابتدا فرض میکنیم که $\underline{\theta}_{g_i}^*$ و $\underline{\theta}_{f_i}^*$ مقادیر بهینه هستند که به صورت روابط (۲۱) و (۲۲) تعریف می شوند:

$$\underline{\theta}_{f_i}^* = \arg \min_{\underline{\theta}_{f_i} \in \Omega_{f_i}} \left(\sup_{x \in \Omega_x} |f_i(x | \underline{\theta}_{f_i}) - f_i(x, t)| \right) \quad (21)$$

$$\underline{\theta}_{g_i}^* = \arg \min_{\underline{\theta}_{g_i} \in \Omega_{g_i}} \left(\sup_{y \in \Omega_y} |g_i(y | \underline{\theta}_{g_i}) - g_i(y, t)| \right) \quad (22)$$

که Ω_{f_i} ، Ω_{g_i} ، Ω_x و Ω_y مقادیر مثبت هستند که محدودید روی $\underline{\theta}_{f_i}$ ، $\underline{\theta}_{g_i}$ ، x و y را تعیین می کنند و به صورت $\Omega_y = \{y | \|y\| \leq M_y\}$ و $\Omega_x = \{x | \|x\| \leq M_x\}$ ، $\Omega_{g_i} = \{\underline{\theta}_{g_i} | \|\underline{\theta}_{g_i}\| \leq M_{g_i}\}$ ، $\Omega_{f_i} = \{\underline{\theta}_{f_i} | \|\underline{\theta}_{f_i}\| \leq M_{f_i}\}$ تعریف می شوند که M_y ، M_x ، M_{g_i} ، M_{f_i} ثابت های مثبت هستند. برای صفحه لغزشی i ام از روابط (۸)، (۹) و (۱۸) داریم:

$$\dot{S}_i(t) = k_i \dot{e}_i(t) = k_i (g_i(y, t) - f_i(x, t) + f_i(x | \underline{\theta}_{f_i}) - g_i(y | \underline{\theta}_{g_i}) - \eta_i \text{sign}(S_i(t)) + d_i(t)) \quad (23)$$

با جایگذاری (۱۶)، (۱۷)، (۲۱) و (۲۲) در رابطه (۲۳) داریم:

$$\dot{S}_i(t) = k_i \left((\underline{\theta}_{g_i}^{*T} - \underline{\theta}_{g_i}^T) \xi_i(y) - (\underline{\theta}_{f_i}^{*T} - \underline{\theta}_{f_i}^T) \xi_i(x) - \eta_i \text{sign}(S_i(t)) + d_i(t) + \omega_i(t) \right) \quad (24)$$

که در رابطه (۲۴)، $\omega_i(t)$ حداقل خطای تخمین است:

$$\omega_i(t) = g_i(y, t) - g_i(y | \underline{\theta}_{g_i}^*) - (f_i(x, t) - f_i(x | \underline{\theta}_{f_i}^*)) \quad (25)$$

که مشتق مرتبه اول از صفحات لغزشی برابر است با:

$$\dot{S}_i(t) = k_i \left(\tilde{\underline{\theta}}_{g_i}^T \underline{\xi}(y) - \tilde{\underline{\theta}}_{f_i}^T \underline{\xi}(x) - \eta_i \text{sign}(S_i(t)) + d_i(t) + \omega_i(t) \right) \quad (26)$$

که $\tilde{\underline{\theta}}_{f_i} = \underline{\theta}_{f_i}^* - \underline{\theta}_{f_i}$ و $\tilde{\underline{\theta}}_{g_i} = \underline{\theta}_{g_i}^* - \underline{\theta}_{g_i}$ هستند. به منظور اثبات پایداری سیستم یک تابع لیپانوف به صورت زیر در نظر می گیریم:

$$V = \frac{1}{2} \sum_{i=1}^n \left(S_i^2 + \frac{k_i}{a_i} \tilde{\underline{\theta}}_{f_i}^T \tilde{\underline{\theta}}_{f_i} + \frac{k_i}{b_i} \tilde{\underline{\theta}}_{g_i}^T \tilde{\underline{\theta}}_{g_i} \right) \quad (27)$$

که در آن به ازای هر $i = 1, \dots, n$ ، $a_i > 0$ و $b_i > 0$ هستند. با مشتق گیری از (۲۷) داریم:

$$\dot{V} = \sum_{i=1}^n S_i \dot{S}_i + \sum_{i=1}^n k_i \left(\frac{1}{a_i} \left(\frac{d \tilde{\underline{\theta}}_{f_i}^T}{dt} \right) \tilde{\underline{\theta}}_{f_i} + \frac{1}{b_i} \left(\frac{d \tilde{\underline{\theta}}_{g_i}^T}{dt} \right) \tilde{\underline{\theta}}_{g_i} \right) \quad (28)$$


با جایگذاری (۲۶) در (۲۸) داریم:

$$\dot{V} = \sum_{i=1}^n k_i S_i \left(\tilde{\underline{\theta}}_{g_i}^T \underline{\xi}(y) - \tilde{\underline{\theta}}_{f_i}^T \underline{\xi}(x) - \eta_i \text{sign}(S_i(t)) + d_i(t) + \omega_i(t) \right) + \sum_{i=1}^n \frac{k_i}{a_i} \left(\frac{d \tilde{\underline{\theta}}_{f_i}^T}{dt} \right) \tilde{\underline{\theta}}_{f_i} + \frac{k_i}{b_i} \left(\frac{d \tilde{\underline{\theta}}_{g_i}^T}{dt} \right) \tilde{\underline{\theta}}_{g_i}$$

در صورتی که شرایط (۱۹) و (۲۰) در نظر گرفته شوند و همچنین با استفاده از شرط (۱۵) یک کران بالا برای $\dot{V}$ در رابطه (۳۰) به صورت زیر است:

$$\dot{V} \leq - \sum_{i=1}^n |k_i| \|S_i(t)\| (\eta_i - \|d(t)\| - \|\omega_i\|) < 0 \quad (30)$$

از (۳۰) می توان نتیجه گرفت که سیستم پایدار مجانبی است. بلوک دیاگرام روش پیشنهادی نیز در فلوچارت ۱ ارائه شده است.



فلوچارت ۱: معماری ساختاری سیستم کنترلی سنکرون سازی آشوب مرجع-پیرو مبتنی بر SMC تطبیقی-فازی

۴- شبیه سازی

در این بخش به منظور بررسی صحت روابط به دست آمده سنکرون سازی دو سیستم آشوبناک چن و لورنز بررسی و پیاده سازی می شوند.

۴-۱ شبیه سازی اول

سیستم آشوبناک چن برای اولین بار توسط چن^۱ و یوتا^۲ معرفی شد [۳۳]. در این قسمت دو سیستم چن با شرایط اولیه متفاوت سنکرون سازی می شوند. معادلات سیستم چن به صورت ذیل تعریف می شوند:

$$\begin{cases} \dot{x}_1 = a(x_2 - x_1) \\ \dot{x}_2 = (c - a)x_1 - x_1x_3 + cx_2 \\ \dot{x}_3 = x_1x_2 - bx_3 \end{cases} \quad (31)$$


این سیستم را با یک سیستم چن با شرایط اولیه متفاوت سنکرون سازی خواهند شد. به همین منظور سیستم چن با معادلات زیر به عنوان سیستم پیرو در نظر گرفته می شود:

¹ Chen

² Ueta


$$\begin{cases} \dot{y}_1 = a(y_2 - y_1) + u_1(t) + d_1(t) \\ \dot{y}_2 = (c - a)y_1 - y_1y_3 + cy_2 + u_2(t) + d_2(t). \\ \dot{y}_3 = y_1y_2 - by_3 + u_3(t) + d_3(t) \end{cases} \quad (32)$$

در این بخش، روش پیشنهادی بر روی دو سیستم چن با معادلات (۳۱) و (۳۲) اعمال شده است. مقادیر اولیه ی سیستم مرجع و سیستم پیرو برابر $(a, b, c) = (35, 3, 28)$ در نظر گرفته شده اند. هر دو سیستم مرجع و پیرو به صورت نامعلوم مدل سازی شده اند و دینامیک های ناشناخته ی آن ها توسط تقریب زننده ی عصبی- فازی تخمین زده می شود. ساختار شبکه ی عصبی- فازی مورد استفاده برای تقریب توابع $f_i(x, \theta_{f_i})$ و $g_i(y, \theta_{g_i})$ ، در شکل ۲ نمایش داده شده است که در آن لایه های ورودی (input)، توابع عضویت ورودی (inputmf)، لایه ورودی (rule)، توابع عضویت خروجی (outputmf) و سپس خروجی (output) مشخص شده اند.



شکل ۲: ساختار شبکه عصبی در نظر گرفته شده برای $f_i(x, \theta_{f_i})$ و $g_i(y, \theta_{g_i})$

تعداد بیست تابع عضویت از نوع گوسی برای $f_i(x, \theta_{f_i})$ و $g_i(y, \theta_{g_i})$ در نظر گرفته شده است. همچنین، تعداد گره های متناظر با قواعد نیز برابر با ۲۰ گره در نظر گرفته شده است. شبکه عصبی تطبیقی- فازی شامل پنج لایه به صورت لایه ورودی، لایه فازی سازی، لایه قواعد بخش مقدم، لایه قواعد بخش تالی، لایه نرمال سازی و خروجی است. شبکه عصبی فازی، پارامترهای $f_i(x, \theta_{f_i})$ و $g_i(y, \theta_{g_i})$ را به گونه ای تعیین می کند که خطای تخمین به حداقل برسد. جاذب سیستم چن در شکل ۳ نمایش داده شده است.



شکل ۳: جاذب سیستم آشوبناک چن


حالت اولیه برای سیستم مرجع برابر $x_0 = [1, 2, 4]^T$ و برای سیستم پیرو برابر $y_0 = [-2, -2, 1]^T$ در نظر گرفته شده است.

مقدار اغتشاش خارجی، $d(t) = \begin{bmatrix} 0.3 \cos(t) \\ 0.2 \sin(t) \\ 0.25 \cos(t) \end{bmatrix}$ فرض شده است. همچنین $\eta = [4, 8, 8]^T$ و برای هر $i = 1, 2, 3$ مقادیر


$a_i, b_i = h$ و $k_i = 1$ در نظر گرفته می شود؛ جایی که $h = 0.001$ و زمان نمونه برداری است. ورودی کنترلی با استفاده از رابطه (۱۸) و قواعد تطبیقی معادلات (۱۹) و (۲۰) به صورت زیر است:

$$u(t) = \begin{bmatrix} f_1(x | \underline{\theta}_{f_1}) - g_1(x | \underline{\theta}_{g_1}) - \eta_1 \text{sat}(S_1(t)) \\ f_2(x | \underline{\theta}_{f_2}) - g_2(x | \underline{\theta}_{g_2}) - \eta_2 \text{sat}(S_2(t)) \\ f_3(x | \underline{\theta}_{f_3}) - g_3(x | \underline{\theta}_{g_3}) - \eta_3 \text{sat}(S_3(t)) \end{bmatrix} \quad (33)$$


لازم به تذکر است که در رابطه (۳۳) به منظور کاهش چترینگ، به جای تابع علامت از تابع اشباع استفاده می نماییم. نتایج حاصل از پیاده سازی، شامل مسیرهای حالت و سیگنال های کنترلی، در شکل های ۴ و ۵ و ۶ نمایش داده شده اند.



شکل ۴: مسیر حالت های x_1 ، y_1 و سیگنال کنترلی $u_1(t)$ سیستم چن به ازای شرایط اولیه $y_0 = [-2, -2, 1]^T$ و $x_0 = [1, 2, 4]^T$




شکل ۵: مسیر حالت های x_2 ، y_2 و سیگنال کنترلی $u_2(t)$ سیستم چن به ازای شرایط اولیه $y_0 = [-2, -2, 1]^T$ و $x_0 = [1, 2, 4]^T$



شکل ۶: مسیر حالت های x_3 ، y_3 و سیگنال کنترلی $u_3(t)$ سیستم چن به ازای شرایط اولیه $y_0 = [-2, -2, 1]^T$ و $x_0 = [1, 2, 4]^T$


همان طور که مشاهده می شود سیستم پیرو به خوبی سیستم مرجع را دنبال می کند. با توجه به اینکه در لحظه اولیه مقادیر اولیه سیستم های مرجع و پیرو یکسان نیستند، نیروی کنترلی در همان لحظه اولیه مقدار بزرگی را برای سنکرون کردن دو سیستم برمی گزینند.

در نهایت سیگنال کنترلی بعد از زمان محدود به صفر می رسد؛ که به دلیل یکسان بودن سیستم مرجع و پیرو است. سیگنال های خطا، e_1 ، e_2 و e_3 در شکل ۷ مشخص شده است.



شکل ۷: خطای سنکرون سازی e_1 ، e_2 و e_3

برای دو سیستم آشوبناک چن با شرایط اولیه متفاوت در شکل ۷ نمایش داده شده اند. همان گونه که مشاهده می شود، تمامی مؤلفه های خطا به صفر همگرا شده اند که بیانگر تحقق کامل سنکرون سازی است. بر همین اساس، مشتق تابع لیپانوف نیز به عنوان یکی از معیارهای ارزیابی پایداری در شکل ۸ ارائه شده است.



شکل ۸: مقدار $\dot{V}(t)$

با توجه به شکل ۸ مشاهده می شود که مقدار $\dot{V}$ در تمامی لحظات منفی است و حداکثر مقدار $\dot{V}_{\max} = -0.8599$ است.

۲-۴ شبیه سازی دوم

سیستم آشوبناک لورنز برای اولین بار در [۱] معرفی شد. در این بخش دو سیستم لورنز با شرایط اولیه متفاوت سنکرون سازی می شوند. معادلات سیستم لورنز به صورت ذیل تعریف می شوند:


$$\begin{cases} \dot{x}_1 = -\sigma(x_1 - x_2) \\ \dot{x}_2 = -x_1x_3 + \rho x_1 - x_2 \\ \dot{x}_3 = x_1x_2 - \beta x_3 \end{cases} \quad (34)$$

این سیستم را با یک سیستم با شرایط اولیه متفاوت سنکرون سازی خواهند شد. به همین منظور سیستم لورنز با معادلات زیر را به عنوان سیستم پیرو در نظر می شود:

$$\begin{cases} \dot{y}_1 = -\sigma(y_1 - y_2) + u_1(t) + d_1(t) \\ \dot{y}_2 = -y_1y_3 + \rho y_1 - y_2 + u_2(t) + d_2(t) \\ \dot{y}_3 = y_1y_2 - \beta y_3 + u_3(t) + d_3(t) \end{cases} \quad (35)$$

در اینجا روش پیشنهاد شده را به سیستم لورنز با معادلات (۳۴) و (۳۵) اعمال می شود که برای هر دو سیستم مرجع و پیرو

جاذب سیستم لورنز نیز در شکل ۹ مشخص شده است. $(\sigma, \beta, \rho) = \left(10, \frac{8}{3}, 28\right)$ است.




شکل ۹: جاذب های سیستم آشوبناک لورنز


شبکه عصبی در نظر گرفته شده در این بخش نیز مشابه شکل ۲ است؛ که تعداد بیست تابع عضویت از نوع گوسی برای $f_i(x, \theta_{f_i})$ و $g_i(y, \theta_{g_i})$ در نظر گرفته شده است. همچنین تعداد گره های مربوط به قواعد نیز بیست تا هستند حالت اولیه برای سیستم مرجع برابر $x_0 = [1, 1, 1]^T$ و برای سیستم پیرو برابر $y_0 = [-5, 3, -10]^T$ در نظر گرفته شده است. مقدار اغتشاش

خارجی، $d(t) = \begin{bmatrix} 0.3 \cos(t) \\ 0.2 \sin(t) \\ 0.1 \cos(t) \end{bmatrix}$ فرض شده است. همچنین $\eta = [7, 8, 12]^T$ و برای هر $i = 1, 2, 3$ مقادیر $a_i, b_i = h$


$k_i = 1$ در نظر گرفته می شود؛ چایی که $h = 0.001$ زمان نمونه برداری است. ورودی کنترلی با استفاده از قوانین کنترلی معادله (۳۳) به دست می آید. نتایج حاصل از شبیه سازی برای ۳۰ ثانیه ابتدایی در شکل های ۱۰، ۱۱، ۱۲ و ۱۳ مشخص شده اند.




شکل ۱۰: مسیر حالت های x_1 ، y_1 و سیگنال کنترلی $u_1(t)$ سیستم لورنز به ازای شرایط اولیه $x_0 = [1, 1, 1]^T$ و $y_0 = [-5, 3, -10]^T$



شکل ۱۱: مسیر حالت های x_2 ، y_2 و سیگنال کنترلی $u_2(t)$ سیستم لورنز به ازای شرایط اولیه $x_0 = [1, 1, 1]^T$ و $y_0 = [-5, 3, -10]^T$




شکل ۱۲: مسیر حالت های x_3 ، y_3 و سیگنال کنترلی $u_3(t)$ سیستم لورنز به ازای شرایط اولیه $x_0 = [1, 1, 1]^T$ و $y_0 = [-5, 3, -10]^T$



شکل ۱۳: خطای سنکرون سازی e_1 ، e_2 و e_3

باتوجه به شکل های ۱۰ تا ۱۳ مشاهده می شود که سیستم پیرو به خوبی سیستم مرجع را دنبال می کند. همچنین دفع اغتشاش نیز به خوبی انجام شده است. با توجه به یکسان بودن سیستم مرجع و پیرو، سیگنال کنترلی بعد از زمان محدود به مقدار صفر رسیده است. مشتق تابع لیاپانوف نیز در این مثال در شکل ۱۴ به عنوان یکی از معیارهای پایداری ارائه شده است.



شکل ۱۴: مقدار $\dot{V}(t)$

با توجه به شکل ۱۴ مقدار $\dot{V}$ در تمامی لحظات منفی است، مقدار $\dot{V}_{\max} = -0.849$ است.

۳-۴ شبیه سازی سوم

در این بخش می خواهیم با استفاده از دینامیک کنترل معرفی شده یک سیستم آشوبناک لورنز را با یک سیستم آشوبناک چن سنکرون سازی کنیم. به این منظور سیستم لورنز را به عنوان مرجع و سیستم چن را به عنوان سیستم پیرو در نظر می گیریم. معادلات سیستم مرجع و پیرو به صورت زیر هستند:


$$\text{Master system (Lorenz)} \begin{cases} \dot{x}_1 = 10(x_2 - x_1) \\ \dot{x}_2 = 28x_1 - x_2 - x_1x_3 \\ \dot{x}_3 = -\frac{8}{3}x_3 + x_1x_2 \end{cases} \quad (36)$$

$$\text{Slave system (Chen)} \begin{cases} \dot{y}_1 = 35(y_2 - y_1) + u_1(t) + d_1(t) \\ \dot{y}_2 = -y_1y_3 + 28y_2 + u_2(t) + d_2(t) \\ \dot{y}_3 = y_1y_2 - 3y_3 + u_3(t) + d_3(t) \end{cases} \quad (37)$$


که شرایط اولیه به برای سیستم مرجع به صورت $x_0 = [2, -1, 5]^T$ و همچنین برای سیستم پیرو برابر $y_0 = [-6, -3, 10]^T$

است. اغتشاش خارجی در نظر گرفته شده به صورت $d(t) = \begin{bmatrix} 0.15 \cos(t) \\ 0.1 \sin(t) \\ 0.1 \cos(t) \end{bmatrix}$ است. همچنین $\eta = [6, 6, 10]^T$ و برای هر


$i = 1, 2, 3$ مقدار $a_i, b_i = h$ و $k_i = 1$ در نظر گرفته می شود. با استفاده از قوانین کنترلی مشابه معادله (۳۳) نتایج شبیه سازی در شکل های ۱۵، ۱۶، ۱۷ و ۱۸ ارائه شده اند.



شکل ۱۵: مسیر حالت های x_1 (لورنز)، y_1 (چن) و سیگنال کنترلی $u_1(t)$ سیستم لورنز به ازای شرایط اولیه $x_0 = [2, -1, 5]^T$ و $y_0 = [-6, -3, 10]^T$




شکل ۱۶: مسیر حالت های x_2 (لورنز)، y_2 (چن) و سیگنال کنترلی $u_2(t)$ سیستم لورنز به ازای شرایط اولیه $x_0 = [2, -1, 5]^T$ و $y_0 = [-6, -3, 10]^T$




شکل ۱۷: مسیر حالت های x_3 (لورنز)، y_3 (چن) و سیگنال کنترلی $u_3(t)$ سیستم لورنز به ازای شرایط اولیه $x_0 = [2, -1, 5]^T$ و $y_0 = [-6, -3, 10]^T$

سیگنال خط e_1 ، e_2 و e_3 به صورت زیر است:




شکل ۱۸: خطای سنکرون سازی e_1 ، e_2 و e_3

همان طور که مشاهده می شود سیستم پیرو به خوبی سیستم مرجع را دنبال می کند؛ همچنین دفع اغتشاش به خوبی انجام شده و خطای سنکرون سازی صفر شده است. با توجه به اینکه سیستم پیرو و مرجع یکسان نیستند، سیگنال کنترلی صفر نشده است و در نهایت در شکل ۱۹، مشتق تابع لیاپانوف نیز به خوبی ارائه شده است.

شکل ۱۹: مقدار $\dot{V}(t)$

می بینیم که مقدار $\dot{V}$ در تمامی لحظات منفی است و بیشینه مقدار $\dot{V}_{\max} = -0.2827$ است. بلوک دیاگرام سیگنالینگ سیستم کنترل نیز در فلوچارت ۲ ارائه شده است.



فلوچارت ۲: بلوک دیاگرام جریان سیگنال ها و حلقه های فیدبک در سیستم کنترلی پیشنهادی

نتیجه گیری

در این مقاله به منظور کنترل سیستم های آشوبناک غیر کانونیکال یک روش جدید کنترل مبتنی بر مود لغزشی تطبیقی-فازی ارائه شد و پایداری آن با استفاده از تئوری لیپانوف اثبات گردید. پارامترهای آزاد سیستم عصبی تطبیقی-فازی تخمین زده شدند و با استفاده از قواعد تطبیقی، نیروی کنترلی لازم برای سنکرون سازی دو سیستم به دست آمد. شبیه سازی های عددی برای سنکرون سازی دو سیستم چن با شرایط اولیه متفاوت، دو سیستم آشوبناک لورنز با شرایط اولیه متفاوت و همچنین سنکرون سازی یک سیستم لورنز با یک سیستم چن مؤثر بودن روش پیشنهادی را تأیید کرد.

مراجع

- [1] Sparrow C., "The Lorenz attractor: Bifurcations, Chaos and Strange Attractors" ed: Springer-Verlag, New York, 1982.
- [2] Yu H., "Research on Three Sliding Mode Synchronization Approaches for a Class of Improved Fractional-Order Hyperchaotic Financial Systems" Engineering Letters. 2026 Mar 1;34(3):881.
- [3] Ghamari S., "Aziz A, Habibi D. A Novel Hybrid Robust Transfer Learning-Based Adaptive Fractional-Order Super-Twisting Sliding Mode Controller Enhanced for Speed Regulation of Brushless DC Motor" IET Control Theory & Applications. 2026 Jan;20(1):e70129.
- [4] Sravanthi G., "Rosalina KM, Reddy TR. Fuzzy logic sliding mode controller based solar PV fed UPQC for improvement of dynamic performance and power quality enhancement in distribution power system" Scientific Reports. 2026 Mar 12;16(1):13319.
- [5] Y.-N. Li, L. Chen, Z.-S. Cai, and X.-z. Zhao, "Experimental study of chaos synchronization in the Belousov-Zhabotinsky chemical system" Chaos, Solitons & Fractals, 2004, vol. 22, pp. 767-771.
- [6] K. J. Y. D. K. HUANG and R. HAI, "An encryption approach to digital communication by using spatiotemporal chaos synchronization" Acta Physica Sinica, 2001, vol. 10, p. 006.
- [7] A. Kiani-B, K. Fallahi, N. Pariz, and H. Leung, "A chaotic secure communication scheme using fractional chaotic systems based on an extended fractional Kalman filter" Communications in Nonlinear Science and Numerical Simulation, 2009, vol. 14, pp. 863-879.
- [8] X.-L. An, J.-N. Yu, Y.-Z. Li, Y.-D. Chu, J.-G. Zhang, and X.-F. Li, "Design of a new multistage chaos synchronized system for secure communications and study on noise perturbation" Mathematical and Computer Modelling, 2011, vol. 54, pp. 7-18.
- [9] L. M. Pecora and T. L. Carroll, "Synchronization in chaotic systems" Physical review letters, 1990, vol. 64, p. 821.
- [10] S. Vaidyanathan, S. Sampath, and A. T. Azar, "Global chaos synchronisation of identical chaotic systems via novel sliding mode control method and its application to Zhu system" International Journal of Modelling, Identification and Control, 2015, vol. 23, pp. 92-100.
- [11] V. Sundarapandian, "Adaptive control and synchronization design for the Lu-Xiao chaotic system" in Computer Networks & Communications (NetCom), ed: Springer, 2013, pp. 319-327.
- [12] A. Boulkroune, S. Hamel, A. T. Azar, and S. Vaidyanathan, "Fuzzy Control-Based Function Synchronization of Unknown Chaotic Systems with Dead-Zone Input" in Advances in Chaos Theory and Intelligent Control, ed: Springer, 2016, pp. 699-718.
- [13] M. Rafikov and J. M. Balthazar, "On control and synchronization in chaotic and hyperchaotic systems via linear feedback control" Communications in Nonlinear Science and Numerical Simulation, 2008, vol. 13, pp. 1246-1255.
- [14] M. P. Aghababa and B. Hashtarkhani, "A new adaptive observer design for a class of nonautonomous complex chaotic systems" Complexity, 2015, vol. 21, pp. 145-153.
- [15] M. Faieghi and D. Baleanu, "Sampled-data nonlinear observer design for chaos synchronization: a Lyapunov-based approach" Communications in Nonlinear Science and Numerical Simulation, 2014, vol. 19, pp. 2444-2453.
- [16] A. Senouci and A. Boukabou, "Predictive control and synchronization of chaotic and hyperchaotic systems based on a T-S fuzzy model" Mathematics and Computers in Simulation, 2014, vol. 105, pp. 62-78.
- [17] I. U. Vadim, "Survey paper variable structure systems with sliding modes" IEEE Transactions on Automatic control, 1977, vol. 22, pp. 212-222.
- [18] Y. Xia and Y. Jia, "Robust sliding mode control for uncertain time-delay systems: an LMI approach" in Proceedings of the American control conference, 2002, pp. 53-58.

- [19] Y. Niu, D. W. Ho, and J. Lam, "Robust integral sliding mode control for uncertain stochastic systems with time-varying delay" *Automatica*, 2005, vol. 41, pp. 873-880.
- [20] J.-C. Juang and C.-M. Lee, "Design of sliding mode controllers with bounded L 2 gain performance: an LMI approach" *International Journal of Control*, 2005, vol. 78, pp. 647-661.
- [21] H. Delavari, R. Ghaderi, A. Ranjbar, and S. Momani, "Fuzzy fractional order sliding mode controller for nonlinear systems" *Communications in Nonlinear Science and Numerical Simulation*, 2010, vol. 15, pp. 963-978.
- [22] H.-T. Yau, "Design of adaptive sliding mode controller for chaos synchronization with uncertainties" *Chaos, Solitons & Fractals*, 2004, vol. 22, pp. 341-347.
- [23] J.-J. Yan, Y.-S. Yang, T.-Y. Chiang, and C.-Y. Chen, "Robust synchronization of unified chaotic systems via sliding mode control" *Chaos, Solitons & Fractals*, 2007, vol. 34, pp. 947-954.
- [24] H. Wang, Z.-z. Han, Q.-y. Xie, and W. Zhang, "Sliding mode control for chaotic systems based on LMI" *Communications in Nonlinear Science and Numerical Simulation*, 2009, vol. 14, pp. 1410-1417.
- [25] H.-T. Yau and C.-L. Chen, "Chattering-free fuzzy sliding-mode control strategy for uncertain chaotic systems" *Chaos, Solitons & Fractals*, 2006, vol. 30, pp. 709-718.
- [26] S. Vaidyanathan and S. Sampath, "Global chaos synchronization of hyperchaotic Lorenz systems by sliding mode control" in *Advances in Digital Image Processing and Information Technology*, ed: Springer, pp. 156-164, 2011.
- [27] M. Sugeno, "On stability of fuzzy systems expressed by fuzzy rules with singleton consequents" *IEEE Transactions on Fuzzy systems*, 1999, vol. 7, pp. 201-224.
- [28] T. Takagi and M. Sugeno, "Fuzzy identification of systems and its applications to modeling and control" *IEEE transactions on systems, man, and cybernetics*, 1985, pp. 116-132.
- [29] M. C. Teixeira and S. H. Zak, "Stabilizing controller design for uncertain nonlinear systems using fuzzy models" *IEEE Transactions on fuzzy systems*, 1999, vol. 7, pp. 133-142.
- [30] A. Abraham, "Adaptation of fuzzy inference system using neural learning" in *Fuzzy systems engineering*, ed: Springer, 2005, pp. 53-83.
- [31] J.-S. Jang, "ANFIS: adaptive-network-based fuzzy inference system" *IEEE transactions on systems, man, and cybernetics*, 1993, vol. 23, pp. 665-685.
- [32] J. L. Castro, "Fuzzy logic controllers are universal approximators" *IEEE transactions on systems, man, and cybernetics*, 1995, vol. 25, pp. 629-635.
- [33] G. Chen and T. Ueta, "Yet another chaotic attractor" *International Journal of Bifurcation and chaos*, 1999, vol. 9, pp. 1465-1466.



Sahand University
of Technology

DOR:

[20.1001.1.23223146.1405.12.2.6.5](https://doi.org/10.1001.1.23223146.1405.12.2.6.5)

Journal of Nonlinear
Systems in Electrical
Engineering

Vol. 12, No. 2

Autumn and Winter 2025

ISSN: 2322 – 3146

<http://jnsee.sut.ac.ir>

Hybrid Deep–Texture Feature Fusion Network for Robust Melanoma Detection in Dermoscopic Images

Nafiseh Gholami, Mansoor Zeinali *

Department of Computer Engineering, Na.C, Islamic Azad University, Najafabad,
Iran

* Corresponding author email: mansoor.zeinali@iau.ac.ir

Abstract

Melanoma is one of the most serious forms of skin cancer, and early detection can support appropriate treatment selection and reduce adverse outcomes. This study presents a two-branch framework for dermoscopic image classification that integrates high-level features extracted by DenseNet121 with local texture features derived from the Local Neighborhood Difference Pattern (LNDP) operator. Images were selected from the ISIC 2019 and HAM10000 datasets, and the task was formulated as binary classification between melanoma and non-melanoma lesions. After resizing images to $224 \times 224 \times 3$ pixels, applying normalization, and performing data augmentation only on the training set, the 1024-dimensional DenseNet121 feature vector was concatenated with a 59-dimensional LNDP histogram. The resulting 1083-dimensional vector was fed into a fully connected classifier with 128 neurons, ReLU activation, dropout with a rate of 0.5, and a Softmax output layer. Performance was evaluated using accuracy, ROC-AUC, PR-AUC, balanced accuracy, MCC, and melanoma recall. The proposed model achieved 97% accuracy, a ROC-AUC of 0.98, balanced accuracy of 0.94, and melanoma recall of 0.90. Ablation and cross-dataset evaluations indicated that fusing deep and texture features improved discriminative performance compared with DenseNet121 alone. Nevertheless, independent external validation and calibration assessment are required before clinical use.

Keywords

Melanoma; DenseNet; LNDP Operator

1. Short Introduction

Melanoma is an aggressive form of skin cancer for which early and accurate diagnosis is essential. Although dermoscopy improves lesion assessment, diagnosis remains challenging because of visual similarity between benign and malignant lesions, image artifacts, and data imbalance. Deep convolutional networks such as DenseNet can learn high-level semantic representations but may not fully capture fine local texture patterns.

2. Proposed Work

The proposed method is a two-stream framework that combines high-level semantic features from DenseNet121 with low-level texture features extracted using the LNDP operator.

Dermoscopic images are resized, normalized, and augmented during training to improve the model's generalization ability. The 1024-dimensional DenseNet121 feature vector and the 59-dimensional LNDP histogram are individually normalized and concatenated into a 1083-dimensional feature vector.

This fused representation is passed through a fully connected layer with 128 ReLU neurons, followed by dropout and a two-class softmax output layer.

The model classifies dermoscopic images into melanoma and benign classes and is evaluated using accuracy, precision, recall, F1-score, ROC-AUC, PR-AUC, balanced accuracy, and MCC.

3. Conclusion

The results indicate that combining DenseNet121 deep features with LNDP texture features improves melanoma classification compared with using either feature type alone.

The proposed model achieved 97% accuracy and a ROC-AUC of 0.98 on the evaluated dermoscopic datasets.

The fusion strategy improved the model's ability to represent both high-level semantic patterns and fine-grained local textures.

Cross-dataset evaluation showed that the proposed method maintained better performance than the DenseNet121 baseline under dataset distribution shifts.

Nevertheless, further validation on larger, independent, and clinically diverse datasets is required before clinical application can be considered.

کنترل تشخیص ملانوما در تصاویر درموسکوپي با استفاده از هم‌جوشي ويژگي‌هاي عميق DenseNet121 و ويژگي‌هاي بافتي LNDP

نفيسه غلامي^۱، منصور زينلي^{۲،۳*}

^۱ دانشجوي کارشناسي ارشد، گروه مهندسي کامپيوتر، واحد نجف آباد، دانشگاه آزاد اسلامي، نجف آباد، ايران

^۲ استاديار، گروه مهندسي برق، واحد نجف آباد، دانشگاه آزاد اسلامي، نجف آباد، ايران

^۳ مرکز تحقيقات پردازش ديجيتال و بينايي ماشين، واحد نجف آباد، دانشگاه آزاد اسلامي، نجف آباد، ايران

* آدرس پست الكترونيكي نويسنده مسئول: mansoor.zeinali@iau.ac.ir



دانشگاه صنعتي سهند

DOR:

[20.1001.1.23223146.1405.12.2.6.5](https://doi.org/10.1001.1.23223146.1405.12.2.6.5)

نشریه سالانه‌اي غيرخطي «مندی برق»

دوره ۱۲ - شماره ۲

پاييز و زمستان ۱۴۰۴

صفحات ۱۰۹ الي ۱۳۳

ISSN: 2322-3146

<http://jnsee.sut.ac.ir>

تاريخ پذيرش: ۱۴۰۵/۶/۱۶

تاريخ بازنگري: ۱۴۰۵/۵/۲۵

تاريخ ارسال: ۱۴۰۴/۱۱/۲۸

چکیده

واژه‌های کلیدی

مبدل افزاینده

طبقه‌بندی ملانوما

شبکه عصبی عمیق

ویژگی‌های سطح پایین

عملگر LNDP

تصاویر درموسکوپي

ملانوما يکي از جدی‌ترین انواع سرطان پوست است و تشخیص زودهنگام آن می‌تواند در انتخاب درمان مناسب و کاهش پیامدهای بیماری مؤثر باشد. در این پژوهش، یک چارچوب دوشاخه برای طبقه‌بندی تصاویر درموسکوپي ارائه می‌شود که ویژگی‌های سطح بالای استخراج‌شده از DenseNet121 را با ویژگی‌های بافتی محلی حاصل از عملگر Local Neighborhood Difference Pattern (LNDP) ادغام می‌کند. تصاویر از مجموعه داده‌های ISIC 2019 و HAM10000 انتخاب شدند و مسئله به صورت دودویی شامل ملانوما و ضایعات غیرملانوما تعریف شد. پس از تغییر اندازه تصاویر به 224×224 پیکسل، نرمال‌سازی و اعمال افزایش داده فقط بر مجموعه آموزش، بردار 1024 بعدی DenseNet121 با هیستوگرام 59 بعدی LNDP از طریق الحاق برداری ترکیب شد. بردار نهایی 1083 بعدی به یک طبقه‌بند تمام‌متصل شامل 128 نورون، تابع فعال‌سازی ReLU، Dropout با نرخ 0.5 و لایه خروجی Softmax وارد شد. ارزیابی با معیارهای دقت، ROC-AUC، PR-AUC، Balanced Accuracy، MCC و Recall کلاس ملانوما انجام گرفت. مدل پیشنهادی به دقت برابر 97% درصد، ROC-AUC برابر 0.98 ، Balanced Accuracy برابر 0.94 و Recall ملانوما برابر 0.90 دست یافت. نتایج مطالعه حذف مؤلفه‌ها و ارزیابی بین مجموعه‌ای نشان داد که ادغام ویژگی‌های عمیق و بافتی، نسبت به DenseNet121 تنها، عملکرد تفکیکی بهتری ایجاد می‌کند. با این حال، برای کاربرد بالینی، اعتبارسنجی خارجی مستقل و ارزیابی دقیق‌تر کالیبراسیون ضروری است.

۱- مقدمه

سرطان پوست يکي از شايع‌ترين بيماري‌هاي پوستي است و ملانوما به‌عنوان بدخيم‌ترين نوع آن، سهم قابل توجهي از مرگ‌ومير سرطان‌هاي پوستي را به خود اختصاص مي‌دهد [۱]. اين سرطان از ملانوسيت‌ها منشأ مي‌گيرد و عواملی مانند تابش فرابنفش، زمينه‌هاي ژنتيکي و برخي عوامل محيطي مي‌توانند زمينه‌ساز بروز آن باشند [۲]. بر اساس گزارش IARC وابسته به سازمان بهداشت جهاني، در سال ۲۰۲۲ بيش از ۱/۵ ميليون مورد جديد سرطان پوست و حدود ۳۳۰ هزار مورد جديد ملانوما در جهان گزارش شده است و نزديک به ۶۰ هزار مرگ نيز به آن نسبت داده مي‌شود [۳]. اين آمار اهميت تشخيص زودهنگام را برجسته مي‌کند، زيرا تاخير در تشخيص مي‌تواند خطر پيشرفت بيماري و مرگ‌ومير را به‌طور جدی افزايش دهد. تشخيص ملانوما در ابتدا به‌شدت به مهارت و تجربه پزشک بستگي دارد و عوامل مختلفی مانند شباهت‌هاي ظاهري بين ضايعات خوش خيم و بدخيم، کيفيت پايين تصاویر و وجود نويزهاي خارجي، باعث ايجاد مشکلات در تشخيص دقيق مي‌شود. با اينکه سيستم‌هاي CAD در سال‌هاي اخير در اين زمينه معرفي شده‌اند، هنوز مشکلاتي در تشخيص الگوهاي پيچيده بافتي و تفاوت‌هاي جزئي ضايعات وجود دارد [۲].

روش‌هاي سنتي تشخيص شامل معاينه بصري، درموسکوپي و در نهايت بيوپسي هستند [۴]. اگرچه درموسکوپي يک روش تصويربرداري غيرتهاجمي است که با بزرگ‌نمايي و حذف بازتاب‌هاي سطحي، امکان مشاهده دقيق‌تر ساختار ضايعات پوستي را فراهم مي‌کند [۵]، اما تشخيص نهايي همچنان به قضاوت متخصص پوست بستگي دارد. مطالعات نشان داده‌اند که دقت تشخيص توسط متخصصان پوست آموزش ديده بين ۶۰ تا ۸۰ درصد متغير است و به ميزان تجربه و مهارت فرد وابستگي زيادي دارد [۶]. از سوي ديگر، شباهت بصري زياد ميان ضايعات خوش خيم و بدخيم، تنوع درون کلاسي ضايعات و همچنين وجود نويزهايي مانند مو يا حباب ژل در تصاویر درموسکوپي، تشخيص دقيق را براي متخصصان و حتي مدل‌هاي خود کار دشوار مي‌سازد [۷].

با پيشرفت فناوري‌هاي پردازش تصوير و يادگيري ماشين، سيستم‌هاي تشخيص به کمک رايانه (CAD) براي شناسايي ضايعات پوستي معرفي شده‌اند. اين سيستم‌ها معمولاً شامل چهار مرحله اصلي: پيش‌پردازش، تشخيص يا بخش‌بندي ضايعه، استخراج ويژگي و در نهايت طبقه‌بندي هستند [۸]. با اينکه مدل‌هاي يادگيري عميق مانند DenseNet قادر به استخراج ويژگي‌هاي پيچيده از تصاویر درموسکوپي هستند، بيشتر اين مدل‌ها تا به امروز بر داده‌هاي عمومي و تصاویر بزرگ‌شده از ضايعات پوستي متمرکز بوده‌اند. چالش‌هاي همچنان باقي مانده شامل مشکلات در شبیه‌سازي دقيق تشخيص ملانوما به‌ويژه در شرايط واقعي مانند کيفيت پايين تصوير و شباهت‌هاي بصري ميان ضايعات است [۴]. در مطالعات اوليه، ويژگي‌هاي سطح پايين مانند رنگ، شکل و بافت به‌عنوان ورودی الگوريتم‌هاي کلاسيکي نظير ماشين بردار پشتيبان (SVM) يا درخت تصميم مورد استفاده قرار گرفتند [۹]. هرچند اين روش‌ها در برخي موارد عملکرد قابل قبولي داشتند، اما به دليل وابستگي زياد به انتخاب ويژگي‌ها و محدوديت در نمايش اطلاعات پيچيده، دقت آن‌ها در مقياس بزرگ رضايتمندبخش نبود [۱۰].

ظهور يادگيري عميق و به‌ويژه شبکه‌هاي عصبي پيچشي (CNN)، نقطه عطفی در پردازش تصاویر پزشکی به شمار مي‌رود [۱۱]. اگرچه بسياري از مدل‌ها از جمله شبکه‌هاي DenseNet پيشرفت‌هاي قابل توجهي در تشخيص ملانوما داشته‌اند، اما مشکلاتي در پردازش تصاویر با کيفيت پايين، داده‌هاي نامتوازن و شباهت‌هاي ظاهري بالا ميان ضايعات خوش خيم و بدخيم همچنان وجود دارد. استفاده هم‌زمان از ويژگي‌هاي سطح پايين و سطح بالا مي‌تواند اين چالش‌ها را کاهش دهد و عملکرد مدل‌ها را بهبود بخشد [۵]. اين شبکه‌ها قادرند به‌صورت خودکار ويژگي‌هاي سطح بالا را از داده‌هاي خام استخراج کنند و در بسياري از زمينه‌ها از جمله تشخيص ملانوما عملکرد بهتري نسبت به روش‌هاي سنتي نشان دهند [۱۲]. با اين حال، استفاده مستقيم از شبکه‌هاي از پيش آموزش ديده مانند VGG16، ResNet50 يا DenseNet که معمولاً بر روي مجموعه داده‌هايي مانند ImageNet آموزش ديده‌اند، با چالش‌هايي همراه است: نخست اينکه اين مدل‌ها براي تصاویر عمومي بهينه شده‌اند و ممکن است در استخراج الگوهاي خاص ضايعات پوستي

عملکرد ضعیف‌تری داشته باشند. دوم آنکه، پیچیدگی محاسباتی بالای این شبکه‌ها موجب افزایش زمان آموزش و استنتاج می‌شود [۱۳].

از سوی دیگر، مطالعات گذشته نشان داده‌اند که ترکیب ویژگی‌های سطح بالا و سطح پایین می‌تواند عملکرد مدل‌ها را به‌طور چشمگیری بهبود بخشد [۱۴]. ویژگی‌های سطح پایین مانند بافت یا الگوهای محلی، به‌ویژه در ضایعاتی که شباهت زیادی به یکدیگر دارند، می‌توانند مکمل مناسبی برای ویژگی‌های عمیق استخراج‌شده توسط شبکه‌های CNN باشند. در همین راستا، عملگرهای مبتنی بر بافت مانند Local Neighborhood Difference Pattern (LNDP) ابزار مناسبی برای توصیف تغییرات شدت پیکسل‌ها در نواحی کوچک تصویر هستند و می‌توانند اطلاعات ارزشمندی درباره ساختار بافتی ضایعه ارائه دهند [۱۵].

بر این اساس، پژوهش حاضر مدلی ترکیبی بر پایه شبکه DenseNet و ویژگی‌های LNDP ارائه می‌دهد تا با ادغام ویژگی‌های چندسطحی، دقت و پایداری در تشخیص خودکار ملانوما افزایش یابد. نوآوری این پژوهش نه در به‌کارگیری صرف DenseNet121 یا LNDP، بلکه در راهبرد فیوژن ناهمگن دومسیره است؛ به‌گونه‌ای که ویژگی‌های معنایی عمیق و ویژگی‌های بافتی محلی به‌صورت مکمل و بدون نیاز به قطعه‌بندی صریح ضایعه یا بهینه‌سازی فراابتکاری، از طریق اتصال برداری ادغام می‌شوند. عملکرد روش پیشنهادی بر روی دو مجموعه داده معتبر ISIC 2019 و HAM10000 ارزیابی می‌شود. همچنین، مقایسه عملکرد مدل ترکیبی با هر یک از مسیرهای DenseNet121 و LNDP به‌صورت مستقل، امکان تحلیل سهم هر مؤلفه و ارزیابی اثربخشی راهبرد هم‌جوشی را فراهم می‌سازد.

ساختار ادامه مقاله به این صورت است: در بخش دوم، پژوهش‌های مرتبط در زمینه تشخیص خودکار ملانوما، شبکه‌های عمیق و توصیفگرهای بافتی مرور می‌شوند. در بخش سوم، روش پیشنهادی، استخراج ویژگی‌های عمیق و بافتی و سازوکار هم‌جوشی تشریح می‌شود. بخش چهارم به معرفی مجموعه داده‌ها، تنظیمات آزمایش و تحلیل نتایج اختصاص دارد. در نهایت، بخش پنجم جمع‌بندی پژوهش، محدودیت‌ها و پیشنهادهایی برای مطالعات آینده را ارائه می‌کند.

۲- مروری بر روش‌های تشخیص ملانوما

تشخیص ملانوما در طول زمان با بهره‌گیری از ابزارها و رویکردهای متنوعی انجام شده است که شامل دو دسته زیر هستند:

(الف) روش‌های بالینی و ابزارهای پزشکی:

یکی از روش‌های سنتی، معاینه چشمی توسط پزشک است که با وجود سرعت و هزینه پایین، به‌شدت به تجربه و مهارت فرد متخصص وابسته است و احتمال بروز خطای انسانی در آن بالاست [۱۶]. درموسکوپ (Dermoscopy) به‌عنوان یکی از ابزارهای غیرتهاجمی پرکاربرد، امکان مشاهده لایه‌های زیرین پوست با بزرگ‌نمایی و نوردهی خاص را فراهم می‌آورد و نسبت به معاینه چشمی دقت بیشتری دارد. با این حال، همچنان نیازمند آموزش تخصصی و وابسته به اپراتور است [۱۷].

در مجموع، وابستگی شدید روش‌های بالینی به تجربه پزشک و محدودیت‌های ذاتی ابزارهای تشخیصی، زمینه را برای بروز خطا فراهم می‌کند و لزوم بهره‌گیری از سامانه‌های تشخیص خودکار و مستقل از عامل انسانی را برجسته می‌سازد.

(ب) رویکردهای محاسباتی:

در حوزه پردازش تصویر و یادگیری ماشین، الگوریتم‌های کلاسیک پردازش تصویر برای استخراج ویژگی‌های بافتی، رنگی و شکلی به کار رفته‌اند. هرچند این روش‌ها می‌توانند در تفسیر خودکار مفید باشند، اما نسبت به نویز و کیفیت پایین تصاویر حساس‌اند

[۱۲]. روش‌های یادگیری ماشین سنتی مانند ماشین بردار پشتیبان (SVM) و جنگل تصادفی (RF) نیز به کار گرفته شده‌اند که در صورت وجود داده‌های خوب، عملکرد قابل قبولی دارند؛ با این حال نیازمند مهندسی ویژگی دستی هستند [۱۸].

با وجود پیشرفت‌های قابل توجه در روش‌های محاسباتی، وابستگی روش‌های کلاسیک به مهندسی ویژگی و ناتوانی آن‌ها در نمایش الگوهای پیچیده، موجب شده است که این رویکردها به تنهایی پاسخگوی چالش‌های تشخیص ملانوما نباشند.

پیشرفت‌های اخیر در یادگیری عمیق به‌ویژه شبکه‌های عصبی پیچشی (CNN) و معماری‌های پیشرفته مانند DenseNet، امکان تشخیص الگوهای پیچیده و خودکارسازی فرایند تشخیص را فراهم کرده‌اند. در سال‌های اخیر، معماری‌های جدید مانند Vision Transformers (ViT) و ConvNeXt در زمینه تشخیص ضایعات پوستی به کار گرفته شده‌اند و توانسته‌اند به نتایج قابل توجهی دست یابند [۱، ۲]. این مدل‌ها با استفاده از خودتوجهی (Self-Attention) و ویژگی‌های چندمقیاسی توانسته‌اند الگوهای پیچیده‌تری را از داده‌های تصویری استخراج کنند. به‌ویژه ViT در پردازش تصاویر پزشکی توانسته است دقت بالایی در تشخیص انواع ضایعات پوستی از جمله ملانوما ارائه دهد و در مقایسه با مدل‌های CNN پیشین، مزایای محسوسی را به همراه داشته است. این مدل‌ها دقتی در حد متخصصان پوست به دست آورده‌اند [۱۹]، [۲۰]. مطالعات اولیه نشان داد که شبکه‌های عصبی پیچشی توانایی دستیابی به عملکردی در سطح متخصصان پوست را دارند [۱۲]؛ ولی این مدل‌ها در استخراج دقیق الگوهای بافتی محلی همچنان با محدودیت‌هایی مواجه‌اند. با وجود پیشرفت‌های قابل توجه در حوزه یادگیری ماشین و عمیق، تشخیص خودکار ملانوما همچنان با چالش‌هایی مواجه است؛ از جمله:

عدم توازن داده‌ها: در مجموعه داده‌های درموسکوپ، تعداد تصاویر خوش‌خیم به مراتب بیشتر از تصاویر بدخیم است و این موضوع باعث بروز مشکل در آموزش مدل‌ها می‌شود [۲۱].

شباهت بصری بین ضایعات: بسیاری از ضایعات خوش‌خیم و بدخیم شباهت‌های ظاهری زیادی دارند که تشخیص دقیق را دشوار می‌سازد.

کیفیت متغیر تصاویر: وجود نویز، تار بودن یا مصنوعات (مانند مو یا بازتاب نور) در تصاویر، عملکرد الگوریتم‌ها را کاهش می‌دهد.

این محدودیت‌ها و چالش‌های مربوط به کیفیت داده‌ها و عدم توازن کلاس‌ها نشان‌دهنده اهمیت توسعه رویکردهای ترکیبی هستند که بتوانند با استفاده از شبکه‌های عمیق (برای یادگیری الگوهای پیچیده) و ویژگی‌های سطح پایین (برای افزایش دقت و پایداری) به عملکرد بهینه دست یابند. این ایده در چارچوب‌های ناهمگن تشخیص سرطان پوست مورد توجه قرار گرفته و نتایج موثری در بهبود عملکرد سیستم‌های طبقه‌بندی گزارش شده است [۲۲]. در یک مطالعه مرتبط دیگر، Rao و Vasumathi چارچوبی چندمرحله‌ای برای قطعه‌بندی و تشخیص سرطان پوست ارائه کردند. در این چارچوب، ابتدا نویز تصاویر با استفاده از فیلتر میانه کاهش یافت و سپس ضایعات پوستی به کمک شبکه R2U-Net قطعه‌بندی شدند. تنظیم فرآیندهای R2U-Net با استفاده از الگوریتم بهینه‌سازی مصنوعی Namib beetle یا ANBO انجام گرفت. پس از قطعه‌بندی، برای کاهش اثر عدم توازن داده‌ها، راهبردهای مختلف تقویت داده اعمال شد و ویژگی‌های آماری، شکلی، SLBT، ویژگی‌های عمیق CNN، ویژگی‌های Haralick و LNDP استخراج شدند. در مرحله نهایی، DenseNet برای تشخیص سرطان پوست به کار رفت و فرآیندهای آن نیز با استفاده از ANBO تنظیم شدند [۲۳]. این چارچوب از نظر پوشش مراحل پردازش و تنوع ویژگی‌ها جامع است و مزیت آن، استفاده هم‌زمان از قطعه‌بندی ضایعه، استخراج ویژگی‌های متنوع و تنظیم فرآیندهای شبکه است. با این حال، وابستگی آن به چندین مرحله پردازشی شامل حذف نویز، قطعه‌بندی، تقویت داده، استخراج مجموعه‌های مختلف ویژگی و بهینه‌سازی فراابتکاری، موجب افزایش پیچیدگی

محاسباتی و دشواری بازتولید می‌شود. همچنین، استفاده هم‌زمان از خانواده‌های متعدد ویژگی، تعیین سهم مستقل هر نوع ویژگی را در عملکرد نهایی دشوار می‌سازد.

از سوی دیگر، مدل‌های multi-scale fusion اخیراً در زمینه تشخیص ضایعات پوستی مورد توجه قرار گرفته‌اند. این مدل‌ها با ترکیب ویژگی‌های مقیاس‌های مختلف تصاویر، توانسته‌اند عملکرد مدل‌های یادگیری عمیق را در تحلیل دقیق‌تر ویژگی‌ها و بافت‌ها ارتقا دهند [۴]. همچنین، استفاده از cross-dataset evaluation در مطالعات اخیر به منظور سنجش قدرت تعمیم مدل‌ها و عملکرد آن‌ها در مجموعه داده‌های مختلف توسعه یافته است. این رویکرد به‌ویژه برای ارزیابی مدل‌ها در شرایط واقعی، که تفاوت‌های قابل توجهی بین مجموعه‌های داده مختلف وجود دارد، ضروری است [۵]. اگرچه پژوهش‌های متعددی به ترکیب ویژگی‌های عمیق یا ادغام چندمقیاسی پرداخته‌اند، اغلب آن‌ها از فیوژن همگن (homogeneous fusion) یعنی ادغام چندلایه از یک شبکه عمیق واحد یا ترکیب چند شبکه مشابه استفاده کرده‌اند. در مقابل، روش حاضر بر پایه یک فیوژن ناهمگن میان دو خانواده کاملاً متفاوت از ویژگی‌ها یعنی ویژگی‌های بافتی LNDP از جنس توصیفگرهای کلاسیک محلی، و ویژگی‌های سطح بالای استخراج شده از DenseNet121 طراحی شده است. این ترکیب، ضعف مدل‌های فوق در نمایش الگوهای بافتی ریز را جبران می‌کند و نوآوری اصلی این مطالعه را شکل می‌دهد. جدول ۱ مقایسه‌ای بین این روش‌ها را نشان می‌دهد.

جدول ۱: مقایسه روش‌های مختلف تشخیص ملانوما

مرجع	محدودیت‌ها	مزایا	نوع روش	روش تشخیص
[۱۶]	وابستگی به تجربه پزشک و احتمال خطای انسانی	سریع و کم‌هزینه	سنتی	معاینه چشمی پزشک
[۱۷]	نیازمند آموزش تخصصی و وابستگی به اپراتور	مشاهده بهتر ساختارهای ضایعه و دقت بیشتر نسبت به معاینه چشمی	ابزار تشخیصی غیرتهاجمی	درموسکوپي
[۱۲]	حساسیت به نویز و کیفیت پایین تصاویر	استخراج ویژگی‌های بافتی، رنگی و شکلی	محاسباتی	روش‌های کلاسیک پردازش تصویر
[۱۹]	نیاز به مهندسی ویژگی دستی	عملکرد مناسب در صورت طراحی ویژگی مناسب	محاسباتی	یادگیری ماشین سنتی، مانند SVM و RF
[۲۰]	نیاز به داده و توان محاسباتی بیشتر	استخراج خودکار ویژگی‌های پیچیده	یادگیری عمیق	شبکه‌های عمیق، مانند CNN و DenseNet
[۲۳]	نیاز به تنظیم مناسب دو مسیر ویژگی	ترکیب ویژگی‌های معنایی و بافتی	ترکیبی	روش پیشنهادی DenseNet121 + LNDP

۳- مواد و روش‌ها

شبکه‌های عصبی مصنوعی (Artificial Neural Networks - ANN) از پیشرفته‌ترین روش‌های یادگیری ماشین هستند که الهام گرفته از ساختار نورون‌های مغز انسان طراحی شده‌اند. این مدل‌ها برای شبیه‌سازی سیستم‌های پیچیده و غیرخطی توسعه یافته و در سال‌های اخیر تحولی بنیادین در حوزه‌هایی مانند بینایی ماشین و تحلیل تصاویر پزشکی ایجاد کرده‌اند [۲۴]. در ساده‌ترین حالت،

يک ANN شامل سه بخش اصلي است: لايه ورودی، لايه‌های پنهان و لايه خروجی. هر نورون در لايه‌های پنهان، ورودی‌ها را از نورون‌های لايه قبلي دریافت کرده و پس از اعمال وزن‌ها و توابع فعال‌سازی (مانند ReLU، Sigmoid یا Tanh)، خروجی‌هایی به لايه بعدي ارسال می‌کند [۲۵].

پیشرفت توان محاسباتی (به‌ویژه GPU ها)، افزایش حجم داده‌های تصویری و توسعه الگوریتم‌های آموزش، منجر به ظهور شبکه‌های عصبی عمیق (Deep Neural Networks - DNNs) شد. این مدل‌ها با داشتن لايه‌های پنهان متعدد، قادرند ویژگی‌های پیچیده‌تری را به‌صورت سلسله‌مراتبی از داده‌ها استخراج کنند [۲۶]. شبکه‌های عمیق در حوزه‌های گوناگون مانند پردازش تصویر، گفتار و زبان طبیعی به نتایج چشمگیری دست یافته‌اند. مطالعات متعددی نشان داده‌اند که عملکرد این شبکه‌ها در تشخیص ضایعات پوستی از جمله ملانوما، قابل مقایسه یا حتی دقیق‌تر از متخصصان پوست است [۱۲، ۲۷، ۲۸].

۱-۳- DenseNet و مزایای آن

یکی از معماری‌های برجسته در حوزه یادگیری عمیق، شبکه‌های عصبی پیچشی متراکم یا DenseNet (Densely Connected Convolutional Networks) معرفی شد [۲۹]. ویژگی اصلی این معماری اتصال مستقیم هر لايه به تمامی لايه‌های بعدي است؛ به‌طوری‌که خروجی هر لايه به‌عنوان ورودی برای تمام لايه‌های بعدي مورد استفاده قرار می‌گیرد. این ساختار موجب تقویت جریان اطلاعات، بهبود انتشار گرادیان و استفاده مجدد از ویژگی‌ها می‌شود و در نهایت با کاهش تعداد پارامترها، کارایی مدل افزایش می‌یابد.

معماری DenseNet از دو بخش اصلی تشکیل شده است:

الف) بلوک‌های متراکم: لايه‌ها در هر بلوک به‌طور متوالی و متراکم با یکدیگر ارتباط دارند و ویژگی‌های استخراج شده از تمامی لايه‌های قبلي به لايه بعد منتقل می‌شود.

ب) لايه‌های انتقالی: این لايه‌ها با استفاده از عملیاتی مانند پیچش و ادغام، ابعاد ویژگی‌ها را کاهش داده و از افزایش بیش از حد پارامترها جلوگیری می‌کنند [۳۰]. مزایای کلیدی این معماری عبارت‌اند از:

کاهش مشکل ناپدید شدن گرادیان: اتصال مستقیم لايه‌ها، امکان انتقال مؤثر گرادیان به لايه‌های ابتدایی را فراهم می‌کند و آموزش شبکه‌های عمیق‌تر را تسهیل می‌نماید [۲۹].

باز استفاده از ویژگی‌ها: با اشتراک‌گذاری ویژگی‌ها بین لايه‌ها، DenseNet قادر است ویژگی‌های متنوعی را با تعداد پارامتر کمتر یاد بگیرد [۳۱].

بهبود دقت و کارایی: مطالعات نشان داده‌اند که DenseNet نسبت به معماری‌هایی مانند ResNet در بسیاری از وظایف طبقه‌بندی تصویر عملکرد بهتری دارد، به‌ویژه در شرایطی که داده‌های آموزشی محدود هستند [۳۲].

در حوزه تحلیل تصاویر پزشکی، از جمله تشخیص ملانوما، معماری DenseNet به دلیل توانایی بالای آن در استخراج ویژگی‌های پیچیده و ظریف از تصاویر درموسکوپي، عملکرد بسیار مناسبی داشته است [۱۲]. با توجه به این ویژگی‌ها، DenseNet گزینه‌ای مناسب برای استخراج نمایش‌های سطح بالای تصاویر درموسکوپي محسوب می‌شود، اما به‌تنهایی قادر به مدل‌سازی دقیق الگوهای بافتی ریز نیست.

۳-۲- ویژگی‌های سطح پایین و عملگر LNDP

ویژگی‌های سطح پایین (Low-Level Features) در پردازش تصویر به آن دسته از ویژگی‌ها که مستقیماً از مقادیر پیکسلی قابل استخراج هستند، بدون نیاز به تحلیل معنایی یا سطح بالا گفته می‌شود. این ویژگی‌ها شامل رنگ، بافت، لبه‌ها، زاویه‌ها و شدت روشنایی می‌شوند و معمولاً به عنوان ورودی الگوریتم‌های بینایی ماشین یا یادگیری ماشین مورد استفاده قرار می‌گیرند [۳۳]. در تصاویر درموسکوپي پوست، الگوهای بافتی ضایعات (مانند لکه‌های تیره یا حاشیه‌های نامنظم) اهمیت ویژه‌ای دارند و می‌توانند با توصیفگرهای بافتی همچون LBP (Local Binary Pattern) و نسخه‌های بهبود یافته آن استخراج شوند [۳۴].

LNDP (Pattern Local Neighborhood Difference) یک توصیفگر بافتی پیشرفته است که به عنوان جایگزینی برای LBP معرفی شده است. در فرایند LNDP، یک پنجره 3×3 روی تصویر حرکت می‌کند و اختلاف شدت بین پیکسل‌های همسایه محاسبه می‌شود. درحالی که LBP تنها اختلاف شدت بین پیکسل مرکزی و همسایه‌ها را در نظر می‌گیرد، LNDP روابط میان همسایه‌ها را نیز بررسی می‌کند. این ویژگی باعث می‌شود LNDP توانایی بالاتری در شناسایی الگوهای ریز و پیچیده داشته باشد و نسبت به تغییرات محلی تصویر حساس‌تر عمل کند [۳۵]. این نوع اطلاعات اغلب توسط شبکه‌های عمیق در لایه‌های بالاتر نادیده گرفته می‌شوند، زیرا شبکه‌ها در سطوح بالاتر بیشتر بر ویژگی‌های انتزاعی و مفهومی تمرکز دارند. LNDP الگوهای دودویی مبتنی بر روابط بین همسایه‌ها تولید کرده و آن‌ها را در قالب هیستوگرام‌های بافتی ذخیره می‌کند [۳۶]. مزایای LNDP در مقایسه با LBP عبارت‌اند از:

- مقاومت بیشتر در برابر نویز.
- توانایی بالاتر در توصیف بافت‌های پیچیده.
- پایداری بهتر در شرایط نوری متغیر.
- کاربرد مؤثرتر در تحلیل تصاویر پزشکی.

انتخاب و به کارگیری ویژگی‌های مناسب برای نمایش دقیق داده‌ها، در فرایند طبقه‌بندی تصاویر پزشکی نقش حیاتی دارد. در این میان، ترکیب ویژگی‌های سطح پایین کلاسیک با ویژگی‌های استخراج شده از شبکه‌های عصبی عمیق به عنوان رویکردی کارآمد در بهبود عملکرد سیستم‌های یادگیری شناخته شده است [۳۷]. چون معماری‌هایی مانند DenseNet توانایی یادگیری نمایش‌های پیچیده و سطح بالا از داده‌ها را دارند و الگوهای مکانی - معنایی گسترده‌تری را در تصاویر شناسایی می‌کنند [۳۸].

۴- روش پیشنهادی


چنانچه بیان شد؛ LNDP به عنوان ابزاری مؤثر برای استخراج ویژگی‌های اولیه از تصاویر درموسکوپي مورد استفاده قرار گرفته است. این ویژگی‌ها می‌توانند ساختارهای ریز ضایعه مانند نقاط تیره، شبکه‌های بافتی یا مرزهای نامنظم را آشکار کنند که در تشخیص ملانوما اهمیت دارند [۳۷]. از سوی دیگر، شبکه‌های عصبی عمیق مانند DenseNet در استخراج ویژگی‌های سطح بالای معنایی بسیار توانمند هستند. ترکیب این دو رویکرد (ویژگی‌های سطح پایین LNDP و ویژگی‌های سطح بالای شبکه عمیق) می‌تواند به صورت مکمل عمل کرده و دقت نهایی در طبقه‌بندی ملانوما را افزایش دهد. پژوهش حاضر نیز بر همین مبنا از این هم‌افزایی بهره می‌برد.

ترکیب این دو نوع ویژگی به گونه‌ای عمل می‌کند که ویژگی‌های سطح پایین نقش مکملی برای ویژگی‌های سطح بالا ایفا کرده و نمایشی جامع‌تر از تصویر ارائه می‌دهند. نتایج پژوهش‌های اخیر نشان داده است که چنین هم‌جوشي ویژگی‌ها به ویژه در حوزه

پزشکی که داده‌ها اغلب با مشکلاتی نظیر نویز، عدم تعادل کلاس‌ها و شباهت ظاهری بین ضایعات مواجه‌اند، باعث افزایش دقت و کاهش خطای طبقه‌بندی می‌شود [۳۸, ۳۹].

در این بخش، معماری روش پیشنهادی معرفی می‌شود. نقطه متمایز این روش نسبت به چارچوب‌های مشابه، نه صرف استفاده از دو خانواده ویژگی LNDP و DenseNet، بلکه راهبرد ترکیب دومسیره آن‌هاست که در آن ویژگی‌های بافتی محلی و ویژگی‌های معنایی عمیق به‌عنوان دو منبع مکمل، بدون واسطه‌گری قطعه‌بندی یا بهینه‌سازی فراابتکاری، مستقیماً از طریق اتصال برداری ادغام می‌شوند.

الگوریتم روش پیشنهادی در شکل ۱ نمایش داده شده است. جزئیات مراحل این روش در ادامه توضیح داده می‌شود.



شکل ۱: بلوک دیاگرام روش پیشنهادی برای طبقه‌بندی نهایی

مرحله ۱- پیش پردازش داده‌ها

به‌منظور آماده‌سازی تصاویر جهت ورود به مدل، مراحل زیر انجام گرفت:

- تصاویر ورودی ابتدا به ابعاد 224×224 پیکسل تغییر اندازه داده شدند تا با ورودی استاندارد شبکه DenseNet121 سازگار باشند. سپس، برای افزایش تنوع داده‌ها و کاهش احتمال بیش‌برازش (Overfitting)، از تکنیک‌های افزایش داده‌ها (Data Augmentation) استفاده شد. این تکنیک‌ها شامل چرخش تصادفی تصاویر در بازه $\pm 20^\circ$ درجه، تغییر

مقیاس (Zoom) در بازه ۰/۹ تا ۱/۱، جابجایی تصادفی تصاویر به اندازه ۱۰٪ در جهت‌های افقی و عمودی و وارونگی افقی (Horizontal Flip) با احتمال ۰/۵ بودند. این تغییرات به‌طور خاص برای داده‌های درموسکوپي مناسب هستند زیرا این نوع تصاویر معمولاً دارای تنوع زیادی از جهات و زوایای مختلف هستند و این تغییرات به مدل کمک می‌کند تا به‌طور مؤثرتر ویژگی‌های بافتی و مرزی ضایعات پوستی را شبیه‌سازی کرده و از سوگیری‌ها جلوگیری کند.

- سپس نرمال‌سازی شدت روشنایی و رنگ برای کاهش اثرات شرایط تصویربرداری مختلف انجام گرفت.
- افزودن داده‌ها (Data Augmentation) فقط روی تصاویر مجموعه آموزش اعمال شد و شامل: چرخش تصادفی در بازه $\pm 20^\circ$ درجه، تغییر مقیاس (Zoom) در بازه ۰/۹ تا ۱/۱، جابجایی افقی/عمودی تا ۱۰٪ ابعاد تصویر، و وارونگی افقی (Horizontal Flip) با احتمال ۰/۵ بود. این تبدیلات برای جلوگیری از نشت اطلاعات، روی مجموعه‌های اعتبارسنجی و آزمون اعمال نشدند.

مرحله ۲- استخراج ویژگی‌ها

در این پژوهش دو دسته ویژگی از تصاویر استخراج می‌شوند:

۱- ویژگی‌های سطح پایین بافتی: از عملگر LNDP (Local Neighborhood Difference Pattern) برای استخراج ویژگی‌های بافتی محلی استفاده گردید. این روش توانایی بالایی در شناسایی ساختارهای ریز و تغییرات شدت نور در ضایعات پوستی دارد.

۲- ویژگی‌های سطح بالا: از معماری DenseNet121 به‌عنوان یک شبکه عصبی پیچشی عمیق بهره گرفته شد DenseNet. قادر است ویژگی‌های معنایی پیچیده‌تری را از تصاویر استخراج کند و بازاستفاده از ویژگی‌ها را بهینه نماید.

مرحله ۳- ترکیب ویژگی‌ها و طبقه‌بندی

در مدل پیشنهادی، برای بهره‌گیری همزمان از اطلاعات سطح بالا و سطح پایین، از روش اتصال برداری (Vector Concatenation) استفاده شده است. روش اتصال برداری به این دلیل انتخاب شد که این روش به‌صورت مؤثر اطلاعات هر دو مسیر ویژگی‌ها (ویژگی‌های بافتی LNDP و ویژگی‌های معنایی DenseNet) را در یک نمای ترکیبی جمع‌آوری می‌کند. این روش یکی از روش‌های ساده و قابل فهم برای ادغام ویژگی‌ها است که به‌ویژه در سیستم‌های یادگیری عمیق با داده‌های ناهمگون مانند ویژگی‌های سطح پایین و سطح بالا مناسب است. انتخاب این روش به دلیل سادگی، قابلیت پیاده‌سازی و حفظ اطلاعات اصلی در هر دو نوع ویژگی بوده است. هرچند روش‌های پیچیده‌تری مانند تنظیم وزنی ویژگی‌ها یا Attention Mechanism می‌توانند برای ادغام ویژگی‌ها استفاده شوند، اما در این مطالعه اتصال برداری به‌عنوان روشی اثربخش و ساده انتخاب شد که به‌طور مؤثر عملکرد مدل را افزایش داد. بدین صورت که خروجی DenseNet (با طول ۱۰۲۴) و ویژگی‌های بافتی LNDP (با طول ۵۹) به‌صورت خطی در کنار یکدیگر قرار گرفته و بردار نهایی با طول ۱۰۸۳ تشکیل می‌شود. برای ایجاد قابلیت ادغام مناسب میان دو مسیر استخراج ویژگی، ابعاد و نحوه نرمال‌سازی بردارها به‌صورت دقیق استانداردسازی شد. تصاویر درموسکوپي به‌صورت خاکستری تبدیل شدند و سپس در پنجره‌هایی به‌اندازه $3 \times 3 \times 3$ ، مقادیر LNDP محاسبه شد. ویژگی‌های بافتی استخراج‌شده توسط LNDP به‌صورت یک هیستوگرام ۵۹ بعدی تولید شدند. از سوی دیگر، تصاویر درموسکوپي پس از انجام مراحل پیش‌پردازش، به‌عنوان ورودی به شبکه DenseNet121 داده می‌شوند و ویژگی‌های سطح بالا از خروجی آخرین لایه پیچشی استخراج می‌گردند. به‌منظور کاهش ابعاد فضایی و تبدیل نقشه‌های ویژگی به یک بردار فشرده، از لایه Global Average Pooling استفاده شده است.

خروجی این لایه یک بردار ویژگی با طول ۱۰۲۴ بُعد است که اطلاعات معنایی و انتزاعی تصویر را در خود جای داده و نمایانگر ویژگی‌های سطح بالای استخراج‌شده توسط شبکه عمیق می‌باشد.

به‌منظور یکسان‌سازی مقیاس دو بردار و جلوگیری از غلبه ویژگی‌های یک مسیر بر مسیر دیگر، هر دو بردار پیش از ادغام تحت نرمال‌سازی Min-Max در بازه [۰,۱] قرار گرفتند. پارامترهای نرمال‌سازی min-max (کمینه و بیشینه) صرفاً بر اساس داده‌های مجموعه آموزش محاسبه شده و سپس بدون هیچ‌گونه بازبرازش، بر روی داده‌های اعتبارسنجی و آزمون اعمال شده‌اند تا از نشت اطلاعات جلوگیری شود:

$$x_{norm} = \frac{x - \min(x)}{\max(x) - \min(x)} \quad (1)$$

در مرحله‌ی ادغام، این دو بردار حاصل از ویژگی‌های LNDP و DenseNet به‌صورت اتصال برداری ترکیب شدند و یک بردار ناهمگن با ابعاد $1083 = 1024 + 59$ تشکیل شد. این بردار، ورودی لایه تمام متصل با ۱۲۸ نورون قرار گرفت که پس از اعمال تابع فعال‌سازی ReLU و Dropout روی آن، به لایه Softmax جهت پیش‌بینی نهایی منتقل شد که نهایتاً خروجی مدل به صورت یکی از دو کلاس «ملانوما» یا «خوش‌خیم» ارائه می‌شود. بنابراین، ساختار نهایی طبقه‌بند به‌صورت زیر است:

Input (1083) → Dense (128, ReLU) → Dropout (p=0.5) → Dense (2, Softmax)

استفاده از لایه‌ی Dropout به میزان ۵۰٪ به‌منظور جلوگیری از بیش‌برازش (Overfitting) انجام گرفت.

لازم به ذکر است که تشابه به‌کارگیری LNDP و DenseNet بین پژوهش حاضر و مطالعه Rao و Vasumathi به انتخاب همین دو خانواده ویژگی محدود می‌شود و نوآوری پژوهش حاضر در این تشابه خلاصه نمی‌شود. در روش مرجع، LNDP یکی از چندین گروه ویژگی (آماري، شکلي، SLBT، CNN، Haralick و LNDP) است که پس از قطعه‌بندی R2U-Net و بهینه‌سازی ANBO در یک زنجیره چندمرحله‌ای استخراج و ترکیب می‌شوند؛ درحالی‌که در روش حاضر، LNDP کنار ویژگی‌های عمیق DenseNet121 به‌عنوان دو مؤلفه مکمل یک معماری دومسیره مطرح است و ادغام آن‌ها از طریق اتصال برداری، بدون قطعه‌بندی صریح و بدون بهینه‌سازی فراابتکاری انجام می‌شود.

۵- شبیه‌سازی‌ها و فرایند آموزش مدل

۵-۱- آموزش سیستم

مدل پیشنهادی با استفاده از کتابخانه‌های TensorFlow و Keras پیاده‌سازی شد. برای آموزش شبکه، از الگوریتم Adam optimizer نرخ یادگیری اولیه ۴-۱۰ و تابع هزینه Cross-Entropy Loss استفاده گردید. فرایند آموزش به‌مدت ۵۰ دوره (Epoch) با اندازه دسته‌ای (Batch Size) برابر با ۳۲ انجام شد تا توازنی میان سرعت پردازش و پایداری گرادینت‌ها ایجاد شود. همچنین برای جلوگیری از بیش‌برازش (Overfitting)، روش‌هایی مانند Early Stopping و Dropout به‌کار گرفته شد.

در این پژوهش از مجموعه‌داده‌های عمومی ISIC 2019 و HAM10000 استفاده شد [۴۱] و [۴۰]. در این پژوهش، تصاویر درموسکوپ از مجموعه‌داده ISIC 2019 Challenge استفاده شده‌اند. دلیل انتخاب این نسخه آن است که ISIC 2019 یکی از کامل‌ترین مجموعه‌داده‌ها از نظر تنوع ضایعات پوستی، کیفیت تصاویر و تعداد نمونه‌های دارای برچسب معتبر است. به‌طور مشخص، از نسخه رسمی منتشرشده در سال ۲۰۱۹ استفاده شده و هیچ داده‌ای از نسخه‌های ISIC 2018 یا ISIC 2020 در این تحقیق مورد استفاده قرار نگرفته است. از آنجا که مجموعه‌داده ISIC 2019 به‌صورت چند کلاسه برچسب‌گذاری شده است، در این پژوهش مسئله به‌صورت دودویی تعریف شد (Melanoma در برابر Benign). بر این اساس، تصاویر دارای برچسب «Melanoma» به‌عنوان

کلاس بدخیم در نظر گرفته شدند و سایر کلاس‌های غیر ملانوما در ISIC 2019 در یک کلاس واحد تحت عنوان «Benign» تجمع شدند. در مجموعه HAM10000 نیز تصاویر با برچسب «melanoma (mel)» در کلاس Melanoma قرار گرفتند و سایر برچسب‌ها به عنوان Benign در نظر گرفته شدند. این موضوع برای قابلیت تکرارپذیری نتایج و مقایسه معتبر با مطالعات پیشین ضروری است. همچنین داده‌های تکمیلی از مجموعه HAM10000 به کار گرفته شده‌اند تا تنوع و حجم نمونه‌های ملانوما و ضایعات خوش خیم افزایش یابد.

برای ایجاد شفافیت کامل در توازن داده‌ها، تعداد تصاویر خوش خیم و بدخیم در هر پایگاه داده به صورت جداگانه استخراج و گزارش شد. در مجموعه داده ISIC 2019، مجموعاً ۸۲۰۰ تصویر مورد استفاده قرار گرفت که شامل ۶۵۰۰ تصویر ضایعه خوش خیم و ۱۷۰۰ تصویر ملانوما بود. در مجموعه داده HAM10000 نیز ۲۸۰۰ تصویر شامل ۲۲۸۰ تصویر خوش خیم و ۵۲۰ تصویر ملانوما به کار گرفته شد. برای جلوگیری از نشت اطلاعات، تقسیم داده‌ها در سطح بیمار یا ضایعه انجام شد. تمام تصاویر متعلق به یک بیمار یا یک ضایعه فقط در یکی از مجموعه‌های آموزش، اعتبارسنجی یا آزمون قرار گرفتند. همچنین نمونه‌های تکراری و تصاویر مشترک میان پایگاه‌های داده شناسایی و حذف شدند. پس از ادغام و پیش‌پردازش داده‌ها، مجموعه نهایی شامل ۱۰۰۰۰۰ تصویر مرکب از ۸۷۸۰ تصویر خوش خیم و ۱۲۲۰ تصویر بدخیم بود. با توجه به ماهیت داده‌های واقعی درموسکوپی، مجموعه نهایی مورد استفاده در این پژوهش ذاتاً نامتوازن بوده است. برای جلوگیری از سوگیری در فرایند تقسیم داده‌ها، از روش تقسیم لایه‌بندی شده استفاده شد تا نسبت کلاس‌ها در مجموعه‌های آموزش، اعتبارسنجی و آزمون ثابت بماند. بنابراین، مجموعه آزمون نیز به صورت نامتوازن باقی مانده و شامل ۱۳۱۷ نمونه خوش خیم و ۱۸۳ نمونه ملانوما است. تمامی معیارهای عملکرد و گزارش‌های آماری ارائه شده در ادامه، بر اساس همین توزیع واقعی داده‌های آزمون محاسبه شده‌اند. تقسیم‌بندی نهایی داده‌ها چنین است: ۷۰٪ داده‌ها شامل ۶۱۴۶ تصویر خوش خیم و ۸۵۴ تصویر بدخیم در مرحله آموزش، ۱۵٪ داده‌ها شامل ۱۳۱۷ تصویر خوش خیم و ۱۸۳ تصویر بدخیم در مرحله اعتبارسنجی و ۱۵٪ تصاویر در مرحله آزمون استفاده شدند.

۲-۵- تحلیل عملکرد مدل پیشنهادی

در این پژوهش، مدل پیشنهادی به منظور ارزیابی عملکرد، پنج بار با بذره‌های تصادفی متفاوت آموزش داده شد تا پایداری و نوسان عملکرد مدل به صورت دقیق سنجیده شود. تمامی معیارهای گزارش شده شامل Accuracy، Precision، Recall و F1-score بر اساس میانگین $\pm$ انحراف معیار محاسبه شده‌اند.

$$Accuracy = (TP + TN) / (TP + TN + FP + FN) \quad (۲)$$

$$Precision(p) = TP / (TP + FP) \quad (۳)$$

$$Recall(r) = TP / (TP + FN) \quad (۴)$$

$$F1_score = 2pr / (p + r) \quad (۵)$$

TP و FN، FP، TN به ترتیب مخفف «منفی واقعی»، «مثبت کاذب»، «منفی کاذب» و «مثبت واقعی» یا تشخیص درست ملانوما هستند. از آنجا که داده‌های آزمون نامتوازن هستند، علاوه بر معیارهای متداول، معیارهای Balanced Accuracy، ضریب همبستگی


متیوز (MCC) و نیز سطح زیر منحنی Precision-Recall برای کلاس ملانوما (PR-AUC/AP) گزارش شد تا عملکرد مدل روی کلاس اقلیت به صورت دقیق‌تر ارزیابی گردد.

$$\text{Balanced Accuracy} = (\text{Recall} + \text{Specificity})/2 \quad (۶)$$

$$\text{Specificity} = \text{TN}/(\text{TN} + \text{FP}) \quad (۷)$$

$$\text{MCC} = (\text{TP} \times \text{TN} - \text{FP} \times \text{FN}) / \sqrt{((\text{TP} + \text{FP})(\text{TP} + \text{FN})(\text{TN} + \text{FP})(\text{TN} + \text{FN}))} \quad (۸)$$

نمودار دقت و خطا در شکل ۲ نشان داده شده است.



شکل ۲. منحنی دقت آموزش و اعتبارسنجی مدل پیشنهادی

نمودارهای دقت و خطا در شکل ۲ نشان می‌دهند که مدل پیشنهادی در طول فرایند آموزش رفتار پایدار و همگرایی مناسبی دارد. دقت در هر دو مجموعه‌ی آموزش و اعتبارسنجی به صورت یکنواخت افزایش یافته و منحنی‌های مربوطه فاصله‌ی اندکی از یکدیگر دارند که بیانگر تعمیم‌پذیری مطلوب مدل و عدم وقوع بیش‌برازش است. همچنین کاهش پیوسته‌ی مقادیر خطا در هر دو مجموعه نشان‌دهنده‌ی یادگیری پایدار و تنظیم مناسب ابرپارامترهای آموزشی است. این نتایج کارایی ترکیب معماری DenseNet با ویژگی‌های بافتی LNDP را در فرایند آموزش و تعمیم مدل تأیید می‌کند.

به منظور حصول اطمینان از پایداری نتایج و کاهش وابستگی ارزیابی مدل به یک تقسیم‌بندی خاص از داده‌ها، در این پژوهش از روش Cross-Validation پنج‌گانه (5-Fold Cross-Validation) استفاده شد. در این روش، کل مجموعه داده به پنج بخش هم‌حجم (Fold) تقسیم و در هر تکرار، چهار بخش برای آموزش و اعتبارسنجی و یک بخش برای آزمون مورد استفاده قرار گرفت. بدین ترتیب، هر بخش دقیقاً یک‌بار نقش مجموعه‌ی آزمون را ایفا کرد و عملکرد نهایی مدل به صورت میانگین $\pm$ انحراف معیار معیارهای ارزیابی پنج تکرار گزارش شد. در تمامی مراحل، داده‌های آموزش و آزمون بدون هم‌پوشانی انتخاب شدند تا از بروز نشت داده جلوگیری گردد. این ساختار سبب می‌شود نتایج مدل از نظر آماری پایدارتر بوده و میزان قابلیت تعمیم آن به نمونه‌های دیده‌نشده دقیق‌تر ارزیابی شود. تمامی نتایج گزارش شده بر اساس پنج اجرای مستقل مدل با مقداردهی اولیه متفاوت وزن‌های شبکه

و ترتیب تصادفی دسته‌ها محاسبه شده‌اند. برای جلوگیری از نشت اطلاعات، تمام پارامترهای پیش‌پردازش، از جمله پارامترهای Min-Max، فقط از بخش آموزش همان Fold محاسبه و سپس روی بخش اعتبارسنجی و آزمون اعمال شدند.

جدول ۲: نتایج حاصل از ۵-Fold Cross-Validation برای مدل DenseNet+LNDP

Fold	Accuracy	AUC	Recall	Precision	F1-Score
1	0.967	0.985	0.952	0.974	0.963
2	0.962	0.981	0.945	0.971	0.958
3	0.971	0.989	0.960	0.978	0.969
4	0.964	0.982	0.949	0.972	0.960
5	0.968	0.987	0.955	0.975	0.965
میانگین $\pm$ SD 0.966 $\pm$ 0.003 0.985 $\pm$ 0.003 0.952 $\pm$ 0.005 0.974 $\pm$ 0.002 0.963 $\pm$ 0.004					

نتایج جدول ۲ نشان می‌دهد که مدل پیشنهادی در تمام پنج تکرار عملکرد پایداری از خود نشان داده و نوسانات معیارها بسیار محدود است. مقدار میانگین AUC برابر با 0.985 ± 0.003 نشان‌دهنده توانایی بسیار بالای مدل در جداسازی نمونه‌های مثبت و منفی است. همچنین میانگین Accuracy برابر 0.966 ± 0.003 و مقدار F1-Score برابر 0.963 ± 0.004 بیانگر تعادل مناسب میان Precision و Recall در طبقه‌بندی نمونه‌ها است. پایین بودن انحراف معیار معیارهای ارزیابی نشان می‌دهد که مدل نسبت به تغییرات تصادفی در تقسیم داده‌ها حساسیت اندکی دارد و قابلیت تعمیم بالایی دارد.

با توجه به نامتوازن بودن توزیع کلاس‌ها در مجموعه آزمون، علاوه بر معیارهای متداول، شاخص‌های مقاوم در برابر عدم توازن نیز محاسبه شد که نتایج یکی آن در جدول ۳ ارائه شده است.


جدول ۳: معیارهای تکمیلی ارزیابی مدل پیشنهادی در حالت نامتوازن

معیار	مقدار (Mean $\pm$ SD)
Balanced Accuracy	0.94 $\pm$ 0.01
MCC	0.77 $\pm$ 0.03
PR-AUC / AP (Melanoma)	0.98 $\pm$ 0.01
AUC (ROC)	0.98 $\pm$ 0.01
Recall (Melanoma)	0.90 $\pm$ 0.01

نتایج جداول ۲ و ۳ نشان می‌دهد که مدل پیشنهادی در تشخیص هر دو کلاس خوش‌خیم و بدخیم از نتایج قابل قبولی برخوردار است.


دقت متعادل شده یا Balanced Accuracy که میانگین Recall و Specificity بوده و به‌ویژه در داده‌های نامتوازن اهمیت دارد، برای کلاس خوش‌خیم که تعداد آن بیشتر است، بالاتر از کلاس بدخیم است. همچنین MCC یا ماتریس همبستگی متیوز که به‌طور متعادل تمامی انواع خطاهای مدل (True Positives, True Negatives, False Positives, False Negatives) را در نظر می‌گیرد. برای کلاس بدخیم که تعداد آن کمتر است، پایین‌تر از خوش‌خیم است که نشان‌دهنده چالش‌های مدل در تشخیص درست ملانوما است.

ماتریس آشفتگی مدل در داده‌های آزمون در شکل ۳ نشان داده شده است.



شکل ۳: ماتریس آشفتگی مدل پیشنهادی در مجموعه آزمون


مطابق شکل ۳، ماتریس آشفتگی در مجموعه آزمون (۱۳۱۷ خوش‌خیم و ۱۸۳ ملانوما)، تعداد True Positive برای ملانوما برابر با ۱۶۵ و False Negative برابر با ۱۸ بوده است. همچنین برای کلاس خوش‌خیم، True Negative برابر با ۱۲۹۰ و False Positive برابر با ۲۷ گزارش شد. این نتایج نشان می‌دهد با وجود نامتوازن بودن داده‌ها، نرخ خطای نوع دوم (FN) در کلاس ملانوما محدود بوده است.



شکل ۴: منحنی ROC مدل پیشنهادی

همان‌طور که در شکل ۴ مربوط به منحنی ROC مشاهده می‌شود، مدل پیشنهادی با دستیابی به مقدار AUC برابر با ۰/۹۸، توانایی خوبی در تفکیک نمونه‌های ملانوما از نمونه‌های غیرملانوما نشان می‌دهد.

نمودار Precision-Recall یک معیار مهم برای ارزیابی مدل‌ها در شرایط نامتوازن داده‌ها است. در این نمودار، Precision و Recall با توجه به کلاس‌بندی صحیح و اشتباه نمونه‌های ملانوما اندازه‌گیری می‌شوند. در حالی که Precision نشان‌دهنده دقت مدل در پیش‌بینی صحیح کلاس مثبت است، Recall میزان حساسیت مدل در شناسایی نمونه‌های کلاس مثبت را ارزیابی می‌کند. مدل‌هایی که در تشخیص بیماری‌های نادر مانند ملانوما عملکرد بالایی دارند، معمولاً دارای Precision و Recall بالاتر در نمودارهای Precision-Recall هستند. در شکل ۵ نمودار Precision-Recall عملکرد مدل پیشنهادی را در برقراری توازن میان دقت (Precision) و حساسیت (Recall) در آستانه‌های مختلف تصمیم‌گیری نشان می‌دهد.



شکل ۵: منحنی Precision-Recall برای کلاس ملانوما

در شکل ۵، مقدار Average Precision (AP) برابر با ۰/۹۸، بیانگر عملکرد مطلوب مدل در شناسایی نمونه‌های ملانوما در دامنه گسترده‌ای از آستانه‌های تصمیم‌گیری است. در مقادیر پایین Recall، مقدار Precision به یک نزدیک است؛ به این معنا که نمونه‌هایی که مدل با اطمینان بالا به عنوان ملانوما شناسایی کرده است، عمدتاً به درستی در این کلاس قرار گرفته‌اند و سهم پیش‌بینی‌های مثبت کاذب در میان پیش‌بینی‌های مثبت پایین بوده است. با افزایش Recall، کاهش تدریجی Precision مشاهده می‌شود که بیانگر مبادله طبیعی میان این دو معیار است. باین حال، مقدار بالای AP نشان می‌دهد که مدل در بخش عمده‌ای از دامنه آستانه‌های تصمیم‌گیری، توازن مناسبی میان Precision و Recall برقرار می‌کند. این ویژگی در کاربردهای پزشکی اهمیت دارد؛ زیرا امکان انتخاب آستانه تصمیم‌گیری متناسب با اولویت‌های بالینی، از جمله افزایش حساسیت برای شناسایی موارد مشکوک به ملانوما، فراهم می‌سازد. باین حال، ارزیابی مستقیم خطای نوع دوم نیازمند گزارش مقدار Recall یا حساسیت در آستانه عملیاتی منتخب است.

برای سنجش نقش هر جزء در مدل پیشنهادی، یک Ablation Study انجام شد تا اثر افزودن ویژگی‌های بافتی LNDP در کنار ویژگی‌های عمیق استخراج‌شده توسط DenseNet بررسی شود. سه پیکربندی شامل DenseNet-only، LNDP-only و ترکیب DenseNet+LNDP تحت شرایط یکسان و با ۵ تکرار مستقل ارزیابی شدند و میانگین $\pm$ انحراف معیارها گزارش شد.

جدول ۴: نتایج مطالعه حذف مؤلفه‌های مدل پیشنهادی

مدل	ROC-AUC	Balanced Accuracy	PR-AUC ملانوما	Recall ملانوما
DenseNet121 + LNDP	0.98 ± 0.01	0.94 ± 0.01	0.98 ± 0.01	0.90 ± 0.01
DenseNet121 تنها	0.94 ± 0.00	0.89 ± 0.01	0.88 ± 0.02	0.92 ± 0.01
LNDP تنها	0.88 ± 0.01	0.78 ± 0.01	0.74 ± 0.02	0.76 ± 0.01

نتایج جدول ۴ نشان می‌دهد مدل ترکیبی DenseNet+LNDP در اغلب شاخص‌ها بهترین عملکرد را دارد و نسبت به DenseNet-only بهبود معناداری ایجاد می‌کند؛ به‌ویژه AUC از ۰/۹۴ به ۰/۹۸ و Balanced Accuracy از ۰/۸۹ به ۰/۹۴ افزایش یافت. همچنین PR-AUC که سطح زیر منحنی Precision-Recall می‌باشد؛ در مورد ملانوما از ۰/۸۸ به ۰/۹۸ رسید که بیانگر ارتقای قابل توجه عملکرد روی کلاس اقلیت است. هرچند Recall ملانوما در DenseNet-only کمی بالاتر گزارش شد (۰/۹۲ در برابر ۰/۹۰)، اما مدل پیشنهادی با افزایش همزمان PR-AUC و Balanced Accuracy، تعادل بهتری بین حساسیت و ویژگی برقرار کرده و احتمالاً با کاهش مثبت‌های کاذب، کیفیت تصمیم‌گیری را بهبود داده است. عملکرد پایین‌تر LNDP-only نیز نشان می‌دهد ویژگی‌های بافتی به‌تنهایی کافی نیستند، اما در کنار ویژگی‌های عمیق نقش تکمیلی و تقویت‌کننده دارند. در مجموع، این مطالعه تأیید می‌کند که هم‌جوشی ناهمگن ویژگی‌های عمیق و سطح پایین با بهبود برخی معیارها همراه بوده و LNDP صرفاً افزوده تزیینی نیست، بلکه سهم مؤثری در افزایش قدرت تفکیک دارد.

این نتیجه، تفاوت رویکرد حاضر با چارچوب Rao و Vasumathi را نیز روشن می‌کند؛ زیرا در روش حاضر سهم LNDP در کنار DenseNet121 به‌صورت مستقل و از طریق پیکربندی‌های DenseNet-only، DenseNet-only و LNDP-only بررسی شده است، درحالی‌که روش مرجع از مجموعه گسترده‌ای از ویژگی‌های ناهمگون شامل LNDP، ویژگی‌های آماری، شکلی، SLBT، Haralick و CNN استفاده می‌کند و تفکیک سهم مستقل هر خانواده ویژگی در آن دشوارتر است.

۳-۵- ارزیابی بین مجموعه‌ای (Cross-Dataset Evaluation)

یکی از معیارهای مهم برای سنجش تعمیم‌پذیری مدل‌های یادگیری عمیق، ارزیابی عملکرد آن‌ها بر روی مجموعه داده‌هایی است که در فرایند آموزش استفاده نشده‌اند. در این پژوهش، به‌دلیل تفاوت‌های قابل توجه میان ساختار برجسب‌ها، کیفیت تصویربرداری و فرمت پیش‌پردازش بین مجموعه داده‌های ISIC، HAM10000 و سایر پایگاه‌های عمومی، امکان انجام یک ارزیابی کامل و استاندارد بین مجموعه داده‌ای فراهم نشد. با این حال، استفاده همزمان از دو پایگاه داده ناهمگون (ISIC 2019 و HAM10000) تا حدی نقش یک سنجش غیرمستقیم تعمیم‌پذیری را ایفا می‌کند، زیرا این دو پایگاه داده از نظر دستگاه تصویربرداری، کیفیت، نوع بیماران و فرایند جمع‌آوری داده متفاوت هستند. بنابراین آموزش مدل بر روی داده‌های ترکیبی، از بیش‌برازش به یک مجموعه خاص جلوگیری کرده و پایداری الگوریتم را افزایش می‌دهد. با وجود محدودیت‌های رایج در ارزیابی بین مجموعه‌ای، در این پژوهش یک سناریوی Cross-dataset به‌صورت استاندارد اجرا و گزارش شد.

برای ارزیابی بین مجموعه‌ای (Cross-Dataset Evaluation)، دو سناریوی استاندارد در نظر گرفته شد.

در سناریوی اول، مدل پیشنهادی صرفاً با استفاده از تصاویر مجموعه داده ISIC 2019 آموزش داده شد (تقسیم داخلی Train/Validation با نسبت ۱۵/۸۵) و سپس بدون هرگونه Fine-tuning یا بازتنظیم پارامترها، بر روی مجموعه داده مستقل HAM10000 ارزیابی گردید [۴۱].

در سناریوی دوم، فرایند به‌صورت معکوس انجام شد؛ به‌طوری‌که مدل ابتدا بر روی مجموعه داده HAM10000 (Train/Validation با نسبت ۱۵/۸۵) آموزش داده شد و ارزیابی نهایی بر روی مجموعه داده ISIC 2019 صورت پذیرفت.

در هر دو سناریو، تمامی مراحل پیش‌پردازش شامل تغییر اندازه تصاویر به 224×224 پیکسل، نرمال‌سازی شدت و استخراج ویژگی‌های بافتی LNDP به‌صورت کاملاً یکسان اعمال شد. همچنین پارامترهای نرمال‌سازی Min-Max صرفاً بر اساس داده‌های آموزش هر سناریو محاسبه و بدون هیچ‌گونه بازبرازش به داده‌های آزمون منتقل شدند تا از بروز نشت اطلاعات جلوگیری شود. اما عملکرد آن همچنان از معماری پایه DenseNet121 بالاتر بود. این نتیجه نشان می‌دهد که روش پیشنهادی از پایداری مناسبی در مواجهه با تغییر توزیع داده‌ها برخوردار است.

جدول ۵: نتایج ارزیابی بین مجموعه‌ای؛ مقادیر به‌صورت میانگین $\pm$ انحراف معیار گزارش شده‌اند و $N=5$ است.

آموزش $\rightarrow$ آزمون	مدل	ROC-AUC	PR-AUC ملانوما	Recall ملانوما	Balanced Accuracy
ISIC 2019 $\rightarrow$ HAM10000	DenseNet121	0.91 ± 0.02	0.72 ± 0.03	0.78 ± 0.03	0.85 ± 0.02
ISIC 2019 $\rightarrow$ HAM10000	مدل پیشنهادی	0.94 ± 0.01	0.79 ± 0.03	0.83 ± 0.02	0.88 ± 0.02
HAM10000 $\rightarrow$ ISIC 2019	DenseNet121	0.90 ± 0.02	0.70 ± 0.04	0.76 ± 0.03	0.84 ± 0.02
HAM10000 $\rightarrow$ ISIC 2019	مدل پیشنهادی	0.93 ± 0.02	0.77 ± 0.03	0.81 ± 0.03	0.87 ± 0.02



مطابق جدول ۵، در هر دو سناریوی ISIC $\rightarrow$ HAM و HAM $\rightarrow$ ISIC، عملکرد مدل پیشنهادی نسبت به DenseNet121 بهبود یکنواختی در AUC و به‌ویژه Recall کلاس ملانوما نشان می‌دهد. اگرچه در ارزیابی بین مجموعه‌ای به دلیل اختلاف توزیع داده‌ها و شرایط تصویربرداری، افت عملکرد نسبت به حالت آموزش ترکیبی مشاهده می‌شود، اما حفظ PR-AUC و Recall بالاتر برای کلاس ملانوما بیانگر پایداری مناسب روش فیوژن ناهمگن در مواجهه با Dataset Shift است. در این ارزیابی، هیچ‌گونه بازآموزی/تنظیم روی مجموعه آزمون انجام نشد و تمام پارامترها صرفاً بر اساس داده‌های آموزش تعیین شدند.

لازم به ذکر است که این ارزیابی بین مجموعه‌ای تحت شرایط سخت‌گیرانه و بدون هرگونه تنظیم دامنه‌ای (Domain Adaptation) انجام شده است؛ بنابراین افت عملکرد مشاهده‌شده نسبت به حالت آموزش ترکیبی، قابل انتظار بوده و بیانگر سنجش واقع‌بینانه توان تعمیم مدل است.

۴-۵- تحلیل خطا

به‌منظور درک بهتر نقاط ضعف مدل، چند نمونه از تصاویر اشتباه طبقه‌بندی‌شده بررسی شدند. شکل‌های جدول ۶ سه نمونه از مواردی را نشان می‌دهد که مدل در تشخیص آن‌ها دچار خطا شده است. این موارد شامل تصاویر با کیفیت پایین، مرزهای نامنظم، الگوهای رنگی غیرمعمول و شباهت ظاهری زیاد میان ضایعات خوش‌خیم و بدخیم هستند.

جدول ۶: نمونه‌هایی از تصاویر اشتباه طبقه‌بندی شده توسط مدل پیشنهادی

تصویر اشتباه	تصویر اشتباه	تصویر اشتباه	تصویر اشتباه
			این تصویر اشتباه به عنوان «dermal nevus» طبقه‌بندی شده است. این تصویر اشتباه به عنوان «dermal nevus» طبقه‌بندی شده است.
			این تصویر اشتباه به عنوان «dermal nevus» طبقه‌بندی شده است. این تصویر اشتباه به عنوان «dermal nevus» طبقه‌بندی شده است.
			این تصویر اشتباه به عنوان «dermal nevus» طبقه‌بندی شده است. این تصویر اشتباه به عنوان «dermal nevus» طبقه‌بندی شده است.

بررسی نمونه‌های اشتباه نشان می‌دهد:

- کیفیت تصویر تأثیر مستقیم بر دقت مدل دارد.
- شباهت زیاد بین ضایعات آتیئیک و ملانوما چالش‌آفرین است.
- الگوهای بافتی نامنظم یا محو، عملکرد LNDP را کاهش می‌دهد.


مشخص است که استفاده از فیلترهای بهبود کیفیت یا روش‌های attention می‌تواند خطا را کاهش دهد.

۵-۵- مقایسه با سایر روش‌ها و مدل‌ها

برای سنجش کارایی مدل پیشنهادی، عملکرد آن با چندین معماری متداول یادگیری عمیق (VGG16، ResNet50 و DenseNet121) و یک رویکرد مبتنی بر ویژگی‌های دستی (LBP + SVM) و همچنین مدل‌های جدیدتر مانند Vision Transformers و EfficientNet اخیراً در زمینه پردازش تصویر و به‌ویژه تشخیص ملانوما نتایج قابل توجهی را ارائه داده‌اند، مقایسه شد. این مدل‌ها توانایی پردازش بهتر ویژگی‌های بافتی و الگوهای پیچیده را دارند. بنابراین، مقایسه با این مدل‌ها می‌تواند به درک بهتر مزیت‌های مدل پیشنهادی در تشخیص دقیق‌تر ملانوما کمک کند.

به‌منظور ارائه‌ی یک مقایسه‌ی جامع و شفاف میان مدل پیشنهادی و روش‌های پایه، شاخص‌های عملکرد شامل Accuracy، Precision، Recall، F1-score و AUC برای تمامی مدل‌ها و روی تمام نمونه‌ها محاسبه و در قالب یک نمودار مقایسه‌ای در شکل ۶ ارائه شد.

Performance Comparison of Proposed DenseNet+LNDP Against Baseline Models



شکل ۶: مقایسه عملکرد مدل پیشنهادی با مدل‌های پایه

همان‌گونه که در شکل ۶ مشاهده می‌شود، مدل پیشنهادی DenseNet+LNDP در تمامی معیارها بهترین عملکرد را نسبت به VGG16، ResNet50، DenseNet121، Vision Transformers، EfficientNet و روش مبتنی بر ویژگی‌های دستی + SVM نشان می‌دهد. این نتایج مؤید اثربخشی ترکیب ویژگی‌های عمیق DenseNet با ویژگی‌های بافتی LNDP در بهبود دقت تشخیص ملانوما است.

جدول ۷: مقایسه عملکرد مدل پیشنهادی با سایر روش‌ها

مدل	Accuracy (%)	Precision (%)	Recall (%)	F1-score (%)	ROC-AUC
VGG16	87.2 ± 0.6	85.9 ± 0.7	88.4 ± 0.6	87.1 ± 0.5	0.90
ResNet50	89.5 ± 0.6	88.1 ± 0.5	90.0 ± 0.5	89.0 ± 0.5	0.92
DenseNet121	91.6 ± 0.4	90.2 ± 0.4	91.8 ± 0.4	91.0 ± 0.4	0.94
ViT	92.1 ± 0.5	91.4 ± 0.6	92.5 ± 0.5	91.9 ± 0.6	0.95
EfficientNet	92.8 ± 0.4	91.7 ± 0.5	93.0 ± 0.4	92.3 ± 0.4	0.96
ویژگی‌های دستی + SVM	84.3 ± 0.7	83.0 ± 0.8	85.1 ± 0.7	84.0 ± 0.8	0.88
مدل پیشنهادی DenseNet121 + LNDP :	97.0 ± 0.3	96.0 ± 0.3	95.0 ± 0.4	96.0 ± 0.4	0.98

مقادیر عددی مربوط به این مقایسه در جدول ۷ گزارش شده‌اند. همان‌طور که جدول نشان می‌دهد، برتری مدل پیشنهادی در معیارهای مختلف با انحراف معیار پایین همراه است که بیانگر پایداری مناسب عملکرد آن در ارزیابی‌های انجام‌شده است. به‌منظور بررسی اینکه بهبود عملکرد مدل پیشنهادی نسبت به معماری‌های پایه از نظر آماری نیز معنی‌دار است یا خیر، آزمایش‌ها پنج بار با بذره‌های تصادفی متفاوت تکرار شدند. میانگین و انحراف معیار معیارهای Accuracy و F1-score برای مدل‌های DenseNet121،

ResNet50 و مدل پیشنهادی محاسبه گردید. برای مقایسه آماری عملکرد، از آزمون t زوجی (Paired t-test) استفاده شد. نتایج نشان داد که اختلاف عملکرد مدل پیشنهادی با DenseNet121 در معیار Accuracy مقدار $p < 0.01$ و در معیار F1-score نیز $p < 0.01$ دارد. اختلاف با ResNet50 نیز با $p < 0.001$ معنی‌دار گزارش شد. برای مقایسه مدل‌ها، اختلاف عملکرد آن‌ها در Fold های یکسان محاسبه شد. با توجه به تعداد کم Fold ها، علاوه بر آزمون t زوجی، آزمون غیرپارامتری-Wilcoxon signed-rank نیز اجرا شد. برای کنترل خطای آزمون‌های متعدد، اصلاح Holm اعمال شد. اندازه اثر و فاصله اطمینان ۹۵ درصد نیز گزارش گردید.

این نتایج نشان می‌دهد که افزایش دقت مدل پیشنهادی، حاصل نوسانات تصادفی یا خطای آماری نیست، بلکه از نظر آماری نیز بهبود معنی‌دار محسوب می‌شود. آزمون t زوجی نشان داد عملکرد مدل پیشنهادی در مقایسه با DenseNet121 و ResNet50 از نظر آماری معنی‌دار است ($p < 0.01$).

برتری مدل پیشنهادی را می‌توان از سه جنبه تحلیل کرد:

۱- تکمیل‌کنندگی ویژگی‌ها: شبکه‌های عمیق غالباً در لایه‌های انتهایی اطلاعات محلی ریز (مانند مرزهای ظریف ضایعه) را از دست می‌دهند، در حالی که LNDP دقیقاً همین اطلاعات را تقویت می‌کند.

۲- معماری DenseNet: اتصال چگال بین لایه‌ها، بازاستفاده‌ی گسترده از ویژگی‌ها را ممکن ساخته و از بروز مشکل ناپدید شدن گرادینان جلوگیری کرده است.

۳- پایداری در داده‌های نامتوازن: در حالی که مدل‌های سنتی مانند SVM در برابر عدم تعادل کلاس‌ها عملکرد ضعیف‌تری دارند، مدل پیشنهادی توانست حتی در شرایطی که نسبت نمونه‌های ملانوما کمتر بود، کارایی خود را حفظ کند.

این تحلیل نشان می‌دهد که مدل پیشنهادی نه تنها از نظر دقت مطلق برتر است، بلکه از نظر قابلیت تعمیم و پایداری در شرایط واقعی نیز مزیت رقابتی دارد.

مرور نمونه‌های نادرست طبقه‌بندی شده نشان داد که بیشتر خطاها مربوط به سه دسته اصلی بودند:

- تصاویر کم کیفیت یا پرنویز: نورپردازی نامناسب و تاری مرزها منجر به طبقه‌بندی اشتباه شد.
- ضایعات آتیپیک یا مشابهت ظاهری بالا: برخی ضایعات خوش خیم از نظر رنگ و ناهمگنی به ملانوما شباهت داشتند و بالعکس.
- عناصر مزاحم: وجود مو یا نشانه‌های تصویربرداری باعث سردرگمی مدل گردید.

از منظر بالینی، خطاهای نوع دوم (False Negative) از اهمیت ویژه‌ای برخوردارند، زیرا عدم تشخیص ملانوما می‌تواند پیامدهای جدی و جبران‌ناپذیری برای بیمار به همراه داشته باشد. در حالی که خطاهای نوع اول (False Positive) ممکن است منجر به درمان‌های غیرضروری شوند، خطاهای نوع دوم به معنای عدم شناسایی موارد ملانوما و عدم درمان به موقع است که می‌تواند موجب پیشرفت سریع بیماری و کاهش شانس بهبود بیمار شود. بنابراین، کاهش خطای نوع دوم یکی از اولویت‌های مهم در طراحی سیستم‌های تشخیص خودکار ملانوما است. در نتایج این پژوهش، مقدار بالای معیار Recall برای کلاس ملانوما نشان‌دهنده آن است که نرخ خطاهای نوع دوم در مدل پیشنهادی پایین بوده و بخش عمده‌ای از نمونه‌های بدخیم به‌درستی شناسایی شده‌اند. از آنجا که در این تحقیق معیارهای عملکرد به صورت درصدی گزارش شده‌اند، مقدار Recall بالا به‌طور غیرمستقیم بیانگر کاهش False Negative است.

با وجود این، برای کاهش هرچه بیشتر ریسک خطاهای حیاتی در کاربردهای بالینی، می‌توان در پژوهش‌های آینده از راهکارهای تکمیلی نظیر ترکیب چند مدل (Ensemble Learning)، استفاده از اطلاعات کلینیکی همراه تصویر و یا افزودن ماژول‌های کمکی در کنار شبکه‌های عمیق بهره گرفت. همچنین، هرچند روش پیشنهادی بدون نیاز به قطعه‌بندی صریح عمل می‌کند، بررسی چارچوب‌هایی که در آن‌ها قطعه‌بندی به‌عنوان یک مرحله‌ی کمکی به‌صورت جداگانه یا در قالب معماری‌های چندوظیفه‌ای به‌کار گرفته می‌شود، می‌تواند به بهبود بیشتر دقت تشخیص در موارد چالش‌برانگیز کمک کند. این محدودیت در مقایسه با روش Rao و (Vasumathi (2024)، که از R2U-Net برای قطعه‌بندی ضایعه استفاده می‌کند، اهمیت بیشتری می‌یابد؛ از این رو، مقایسه مستقیم میان فیوژن ویژگی‌های مبتنی بر قطعه‌بندی و فیوژن بدون قطعه‌بندی می‌تواند یکی از مسیرهای مهم پژوهش‌های آینده باشد.

۶- نتیجه‌گیری

در این پژوهش، یک چارچوب دوشاخه برای طبقه‌بندی تصاویر درموسکوپی ارائه شد که ویژگی‌های سطح بالای DenseNet121 را با ویژگی‌های بافتی LNDP ادغام می‌کند. نتایج ارزیابی نشان دادند که این ترکیب، در مقایسه با استفاده مستقل از DenseNet121 یا LNDP، ROC-AUC، PR-AUC و Balanced Accuracy را بهبود می‌دهد. با این حال، کاهش جزئی Recall ملانوما در مقایسه با DenseNet121 تنها نشان می‌دهد که بهبود عملکرد کلی الزاماً به معنای افزایش حساسیت در آستانه تصمیم پیش‌فرض نیست. بنابراین، در کاربردهایی که کاهش موارد منفی کاذب اولویت دارد، انتخاب آستانه تصمیم، یادگیری حساس به هزینه و گزارش معیارهای بالینی باید در نظر گرفته شود. ارزیابی بین مجموعه داده‌ها نیز نشان داد که مدل ترکیبی در برابر تغییر توزیع داده عملکرد بهتری از DenseNet121 دارد، اما افت عملکرد همچنان وجود دارد. محدودیت‌های اصلی مطالعه شامل ابهام احتمالی در هم‌پوشانی نمونه‌ها، نبود اعتبارسنجی خارجی مستقل، نبود تحلیل کالیبراسیون و نیاز به شفاف‌سازی پروتکل تقسیم داده‌ها است. مطالعات آینده باید ارزیابی بیمارمحور، اعتبارسنجی چندمرکزی، تحلیل فاصله اطمینان، کالیبراسیون احتمال و مقایسه با روش‌های جدیدتر را دنبال کنند. همچنین، آزمایش ترکیب سایر ویژگی‌های سطح پایین نظیر LBP یا ویژگی‌های رنگی و گسترش این چارچوب به سامانه‌های تصمیم‌یار بالینی با در نظر گرفتن اطلاعات کلینیکی بیماران، می‌تواند مسیرهای ارزشمندی برای تحقیقات آتی فراهم سازد.

مراجع

- [1] U. Leiter, T. Eigentler, and C. Garbe, "Epidemiology of skin cancer," in *Sunlight, Vitamin D and Skin Cancer*. New York, NY, USA: Springer, 2015, pp. 120–140.
- [2] C. Conforti and I. Zalaudek, "Epidemiology and risk factors of melanoma: A review," *Dermatology Practical & Conceptual*, vol. 11, no. S1, Art. no. e2021161S, Jul. 2021, doi: 10.5826/dpc.11S1a161S.
- [3] International Agency for Research on Cancer (IARC), World Health Organization, *Skin Cancer*. Lyon, France: IARC, 2024.
- [4] J. Dinnes et al., "Dermoscopy, with and without visual inspection, for diagnosing melanoma in adults," *Cochrane Database of Systematic Reviews*, no. 12, Art. no. CD011902, 2018, doi: 10.1002/14651858.CD011902.pub2.
- [5] V. K. Kohli, C. Kohli, and A. Singh, "Cellular pathology, inflammation, and repair," in *Comprehensive Multiple-Choice Questions in Pathology: A Study Guide*. Singapore: Springer, 2022, pp. 1–7.
- [6] A. A. Jeny, A. N. M. Sakib, M. S. Junayed, K. A. Lima, I. Ahmed, and M. B. Islam, "SkNet: A convolutional neural networks based classification approach for skin cancer classes," in *Proc. 2020 23rd Int. Conf. Computer and Information Technology (ICCIT)*, 2020, pp. 1–6.
- [7] K. Anderson and S. S. Hori, "Image classification of skin cancer: Using deep learning as a tool for skin self-examinations," in *International Symposium on Mathematical and Computational Oncology*. Cham, Switzerland: Springer, 2021, pp. 3–8.
- [8] C. Barata, M. E. Celebi, and J. S. Marques, "A survey of feature extraction in dermoscopy image analysis of skin cancer," *IEEE Journal of Biomedical and Health Informatics*, vol. 23, no. 3, pp. 1096–1109, May 2019.
- [9] S. N. Hồng et al., "The epidemiology of skin cancer at the National Hospital of Dermatology and Venereology from 2017–2021," *Tạp chí Da liễu học Việt Nam*, no. 36, 2022.

- [10] S. Tokez et al., "Incidence of multiple vs first cutaneous squamous cell carcinoma on a nationwide scale and estimation of future incidences," *JAMA Dermatology*, vol. 156, no. 12, pp. 1300–1306, 2020.
- [11] S. K. Zhou, H. Greenspan, C. Davatzikos, J. S. Duncan, B. van Ginneken, A. Madabhushi, J. L. Prince, D. Rueckert, and R. M. Summers, "A review of deep learning in medical imaging: Imaging traits, technology trends, case studies with progress highlights, and future promises," *Medical Image Analysis*, vol. 74, Art. no. 102254, 2021, doi: 10.1016/j.media.2021.102151.
- [12] A. Esteva et al., "Dermatologist-level classification of skin cancer with deep neural networks," *Nature*, vol. 542, no. 7639, pp. 115–118, 2017.
- [13] J. Daghrir, L. Tlig, M. Bouchouicha, and M. Sayadi, "Melanoma skin cancer detection using deep learning and classical machine learning techniques: A hybrid approach," in *Proc. 2020 5th Int. Conf. Advanced Technologies for Signal and Image Processing (ATSIP)*, 2020, pp. 1–5.
- [14] N. C. Codella et al., "Skin lesion analysis toward melanoma detection: A challenge at the 2017 International Symposium on Biomedical Imaging (ISBI), hosted by the International Skin Imaging Collaboration (ISIC)," in *Proc. 2018 IEEE 15th Int. Symp. Biomedical Imaging (ISBI)*, 2018, pp. 168–172.
- [15] A. Murugan, S. A. H. Nair, and K. S. Kumar, "Detection of skin cancer using SVM, random forest and kNN classifiers," *Journal of Medical Systems*, vol. 43, no. 8, Art. no. 269, 2019.
- [16] A. R. J. P. Menzies et al., "Diagnostic accuracy of dermoscopic structures and patterns used in melanoma detection," *JAMA Dermatology*, vol. 157, no. 9, pp. 1078–1088, 2021, doi: 10.1001/jamadermatol.2021.2642.
- [17] H. Kittler, H. Pehamberger, K. Wolff, and M. Binder, "Diagnostic accuracy of dermoscopy," *The Lancet Oncology*, vol. 3, no. 3, pp. 159–165, 2002.
- [18] P. Tschandl, C. Rosendahl, and H. Kittler, "The HAM10000 dataset: A large collection of multi-source dermatoscopic images of common pigmented skin lesions," *Scientific Data*, vol. 5, Art. no. 180161, 2018.
- [19] M. Wei et al., "A skin disease classification model based on DenseNet and ConvNeXt fusion," *Electronics*, vol. 12, no. 2, Art. no. 438, 2023.
- [20] S. Kitada and H. Iyatomi, "Skin lesion classification with ensemble of squeeze-and-excitation networks and semi-supervised learning," *arXiv:1809.02568*, 2018.
- [21] A. Cassidy et al., "The ISIC skin lesion analysis benchmark: Methods and recommendations," *Medical Image Analysis*, vol. 75, Art. no. 102305, 2022, doi: 10.1016/j.media.2021.102305.
- [22] T. Saba, M. A. Khan, A. Rehman, and S. L. Marie-Sainte, "Region extraction and classification of skin cancer: A heterogeneous framework of deep CNN features fusion and reduction," *Journal of Medical Systems*, vol. 43, no. 9, Art. no. 289, 2019.
- [23] N. Raghava Rao and D. Vasumathi, "Segmentation and detection of skin cancer using deep learning-enabled artificial Namib beetle optimization," *Biomedical Signal Processing and Control*, vol. 96, pt. B, 2024.
- [24] S. Haykin, *Neural Networks and Learning Machines*, 3rd ed. Upper Saddle River, NJ, USA: Pearson, 2009.
- [25] I. Goodfellow, Y. Bengio, and A. Courville, *Deep Learning*. Cambridge, MA, USA: MIT Press, 2016.
- [26] Y. LeCun, Y. Bengio, and G. Hinton, "Deep learning," *Nature*, vol. 521, no. 7553, pp. 436–444, 2015.
- [27] G. Litjens et al., "A survey on deep learning in medical image analysis," *Medical Image Analysis*, vol. 42, pp. 60–88, 2017.
- [28] N. C. Codella et al., "Deep learning ensembles for melanoma recognition in dermoscopy images," *IBM Journal of Research and Development*, vol. 61, nos. 4–5, pp. 5:1–5:15, 2017.
- [29] G. Huang, Z. Liu, L. van der Maaten, and K. Q. Weinberger, "Densely connected convolutional networks," in *Proc. IEEE Conf. Computer Vision and Pattern Recognition (CVPR)*, 2017, pp. 4700–4708.
- [30] F. Iandola, M. Moskewicz, S. Karayev, R. Girshick, T. Darrell, and K. Keutzer, "DenseNet: Implementing efficient convnet descriptor pyramids," *arXiv:1404.1869*, 2014.
- [31] N. N. Prakash, V. Rajesh, D. L. Namakhwa, S. D. Pande, and S. H. Ahammad, "A DenseNet CNN-based liver lesion prediction and classification for future medical diagnosis," *Scientific African*, vol. 20, Art. no. e01629, 2023.
- [32] F. Chollet, "Xception: Deep learning with depthwise separable convolutions," in *Proc. IEEE Conf. Computer Vision and Pattern Recognition (CVPR)*, 2017, pp. 1251–1258.
- [33] R. C. Gonzalez and R. E. Woods, *Digital Image Processing*, 3rd ed. Upper Saddle River, NJ, USA: Pearson, 2009.
- [34] T. Ojala, M. Pietikäinen, and T. Mäenpää, "Multiresolution gray-scale and rotation invariant texture classification with local binary patterns," *IEEE Transactions on Pattern Analysis and Machine Intelligence*, vol. 24, no. 7, pp. 971–987, 2002.
- [35] M. Verma and B. Raman, "Local neighborhood difference pattern: A new feature descriptor for natural and texture image retrieval," *Multimedia Tools and Applications*, vol. 77, no. 10, pp. 11843–11866, 2018.
- [36] Y. Dong et al., "Locally directional and extremal pattern for texture classification," *IEEE Access*, vol. 7, pp. 87931–87942, 2019.
- [37] A. Mahbod, G. Schaefer, I. Ellinger, R. Ecker, A. Pitiot, and C. Wang, "Fusing fine-tuned deep features for skin lesion classification," *Computerized Medical Imaging and Graphics*, vol. 71, pp. 19–29, 2019.

- [38] T. Majtner, S. Yildirim-Yayilgan, and J. Y. Hardeberg, "Combining deep learning and hand-crafted features for skin lesion classification," in Proc. 2016 6th Int. Conf. Image Processing Theory, Tools and Applications (IPTA), 2016, pp. 1–6.
- [39] P. Bansal, R. Garg, and P. Soni, "Detection of melanoma in dermoscopic images by integrating features extracted using handcrafted and deep learning models," Computers & Industrial Engineering, vol. 168, Art. no. 108060, 2022.
- [40] M. Combalia et al., "Validation of artificial intelligence prediction models for skin cancer diagnosis using dermoscopy images: The 2019 International Skin Imaging Collaboration Grand Challenge," The Lancet Digital Health, vol. 4, no. 5, pp. e330–e339, May 2022, doi: 10.1016/S2589-7500(22)00021-8.
- [41] V. Rotemberg et al., "A patient-centric dataset of images and metadata for identifying melanomas using clinical context," Scientific Data, vol. 8, Art. no. 34, 2021, doi: 10.1038/s41597-021-00815-z.

نشریه سامانه‌های غیرخطی در مهندسی برق نشریه‌ای علمی-پژوهشی است که جدیدترین نتایج پژوهش‌های بنیادی، کاربردی و توسعه‌ای در زمینه سامانه‌های غیرخطی مهندسی برق را چاپ می‌کند. از میان مباحث موردنظر این نشریه می‌توان به موارد زیر اشاره کرد:

- نور غیرخطی و کاربردهای آن
- سامانه‌های دینامیکی غیرخطی و کاربردهای آنها
- ماشین‌های الکتریکی و سامانه‌های قدرت شامل شبکه‌های تولید، انتقال و توزیع
- مدل‌سازی، شناسایی، تخمین، کنترل، بهینه‌سازی و پیاده‌سازی عملی الگوریتم‌های تحمل‌پذیر عیب
- آشوب و سنکرون‌سازی
- سامانه‌های هابیرید، سویچینگ و چندعامل
- رباتیک و بینایی ماشین
- شبکه‌های مخابراتی، سیستم‌های الکترونیکی و مبدل‌های داده
- پردازش سیگنال‌ها، تصاویر و ویدئو و اسناد، بازشناسی الگو

فرمت نگارش مقالات

مقالات در حال حاضر فقط به زبان فارسی پذیرفته می‌شوند. مقالات ارسالی باید به ترتیب شامل بخش‌های زیر باشند:

عنوان (فارسی)، نام نویسندگان همراه با نام مؤسسه متبوع هر نویسنده، چکیده (فارسی)، واژه‌های کلیدی (فارسی)، مقدمه، بدنه مقاله، نتیجه‌گیری، سپاسگزاری (در صورت وجود)، پیوست (در صورت وجود)، مراجع، شکل‌ها، جداول و تصاویر.

شماره‌گذاری بخش‌ها می‌بایست مطابق شماره‌گذاری مرسوم عددی باشد.

شیوه تدوین (مقاله فقط فارسی)

متن مقالات شامل چکیده، بدنه مقاله، مراجع و زیرنویسها باید با فونت B zar ۱۲ و با فاصله double میان خطوط، در صفحات A4 یک‌رو و تک ستونی با استفاده از نرم‌افزار Word 2010 تهیه شود. علاوه بر این، فایل PDF مقاله (بدون ذکر نام نویسندگان و مؤسسه متبوع و آدرس ایمیل) نیز می‌بایست ارسال شود.

آدرس نویسندگان

آدرس پستی کامل همه نویسندگان همراه با شماره تلفن و دورنگار (فکس) و نشانی الکترونیکی (E-Mail) نویسنده عهده‌دار مکاتبات (که الزاماً می‌بایست عضو هیأت علمی باشند) در برگه مستقلی چاپ و به همراه مقاله ارسال گردد.

چکیده

هر مقاله باید شامل عنوان (فارسی)، چکیده مقاله (فارسی) در حداکثر ۲۰۰ واژه، واژه‌های کلیدی (فارسی) در حداکثر ۵ واژه باشد.

شکل‌ها و تصاویر

در هنگام ارسال مقاله به منظور دآوری نیازی به ارسال اصل شکل‌ها و تصاویر نیست، ولی رونوشت ارسالی باید واضح باشد. پس از تأیید مقاله، ارسال اصل شکل‌ها و تصاویر (با فرمت Tiff) برای چاپ مقاله ضروری است. شکل‌ها و تصاویر نباید قابل ویرایش باشند.

مراجع

به کلیه مراجع (به تعداد حداقل ۱۰ مرجع) باید در متن ارجاع داده شده باشد. مراجع باید تابع استاندارد IEEE بوده و با شماره، مشخص گردند و جزئیات آنها به شرح زیر در پایان مقاله ظاهر گردد:

مقالات: شماره مرجع، نام خانوادگی و نام کامل همه نویسندگان، "عنوان مقاله"، نام کامل مجله یا کنفرانس، سال انتشار یا تاریخ برگزاری، شماره مجله یا شماره جلد، شماره صفحات.

کتابها: شماره مرجع، نام خانوادگی و نام کامل همه نویسندگان، عنوان کتاب، نام مترجم، نام کامل ناشر، سال انتشار.

واحد ها

کلیه مقالات باید از واحد استاندارد SI در تمام بخش های مقاله استفاده نمایند. در کنار واحد SI می توان از واحد انگلیسی در داخل پرانتز نیز استفاده نمود.

تعداد صفحات مقاله

حداکثر تعداد صفحات مقالات در هنگام چاپ، ۱۲ صفحه است. برای چاپ صفحات بیشتر و یا رنگی، لازم است هزینه ای برای هر صفحه به حساب نشریه واریز شود.

فرآیند ارسال مقاله

مقالات قابل چاپ در نشریه شامل مقالات کامل پژوهشی و مقالات کوتاه پژوهشی هستند. مقالات ارسالی نباید در هیچ نشریه داخلی و یا خارجی چاپ شده باشند و یا در حال داوری باشند. لازم است نسخه اولیه مقاله به صورت تک ستونی در دو نسخه (یک نسخه با نام نویسندگان و مؤسسه متبوع نویسندگان با فرمت docx و یک نسخه بدون نام نویسندگان و مؤسسه متبوع نویسندگان و آدرس ایمیل با فرمت pdf. به منظور ارسال به داوران) از طریق سایت اینترنتی نشریه به آدرس <http://jnsee.sut.ac.ir> برای داوری ارسال شود. داوری به شکل Double Blind Review است و نسخه اولیه مقالات به داوران متخصص ارسال می شود. در پایان، تأیید یا رد هر مقاله توسط هیأت تحریریه نشریه انجام خواهد شد. سردبیر نشریه نتیجه داوری را برای نویسنده عهده دار مکاتبات ارسال خواهد کرد. در صورتی که نیاز به تصحیح مقاله باشد، تصحیحات باید منحصراً محدود به موارد اصلاحی ذکر شده باشند. در سایر موارد، نویسنده لازم است سردبیر را در جریان هر گونه تغییر و یا تصحیح دیگری قرار دهد. در هر صورت، مسئولیت صحت و سقم مطالب بر عهده نویسنده/نویسندگان مقاله خواهد بود.

در صورتی که مقاله برای چاپ پذیرفته شود، لازم است اصل مقاله مطابق فرمت استاندارد نشریه از طریق سایت نشریه ارسال شود. پس از چاپ، یک نسخه از نشریه به هر یک از نویسندگان اهدا خواهد شد.

حق کپی رایت

در صورت پذیرش مقاله برای چاپ، نویسندگان لازم است فرم انتقال حق انتشار آن به "دانشگاه صنعتی سهند" را تکمیل و به همراه اصل مقاله ارسال نمایند. نویسندگان لازم است موافقت کتبی دارندگان حق کپی بخش هایی از مقاله که از مراجع و منابع دیگر نسخه برداری شده است را دریافت و به دفتر مجله ارسال نمایند.

بدینوسیله از کلیه اساتید و پژوهشگران برای ارسال مقالات خویش در این نشریه دعوت به عمل می آید. خواهشمند است مقالات خود را از طریق سایت نشریه به آدرس <http://jnsee.sut.ac.ir> ارسال فرمایید.