



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 غیرنظمی «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-لایبیلر 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؛ استنتاج 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 ماکسیمی	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 ثبت‌شده 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 ماحالانویس 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 ماحالانویس (D_M^2) تنها از روی داده‌های آموزش دامنه مبدأ استخراج شدند و داده‌های آزمون در هیچ‌یک 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 مبنا، 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 پایداری 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:

$$h_k = G_\theta(X_k) \quad (4)$$

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]:

$$Reduction Factor = \frac{1}{N} + \frac{1}{D_k^2} \quad (5)$$


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	بردار $h_k \in R^{64}$ پیش از لایه Softmax	ورودی مازول‌های 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 ، مازول 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 مازول تشخیص رانش (بخش ۳-۶) و مازول 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 مازول 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

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

- امتیاز F1^۲:

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

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-لایبلر^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-لایبلر 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 [۱۷-۱۹].

- 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 مقداری اولیه وزن‌ها و تصادفی بودن 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. باین حال، 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. محدود بودن پراکندگی این شاخص‌ها نشان‌دهنده حساسیت نسبتاً کم مدل به مقداری اولیه و تصادفی بودن فرایند آموزش است [۱۶، ۱۷، ۵۱].



شکل ۲ - روند همگرایی تابع هزینه اتروپی مقاطع مدل 1D-CNN سبک 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 به عنوان 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

^۱ Adaptive Moment Estimation (Adam)

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 بازایی 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، فاصله‌ماهیالانویس 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 $F1$ ، ΔAcc 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 مجموعه‌داده‌های مستقل، گزارش معیارهای اختصاصی تشخیص رانش مانند نرخ هشدار کاذب، نرخ کشف و تأخیر تشخیص، و تحلیل حساسیت مدل نسبت به آستانه فاصله مالا‌نویس 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 قابل‌اعتمادتر را برای کاربردهای بلندمدت فراهم سازد [۳، ۷، ۳۲-۳۴].

مراجع

1. 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.
2. L. Xue, Y. Li, and Y. Deng, "Multicomponent porous metal oxide semiconductors for advanced gas sensing," *Micro Nano Sci.*, vol. 1, p. 2, 2025.
3. 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.
4. J. Fonollosa, I. Rodríguez-Luján, and R. Huerta, "Chemical gas sensor array dataset," *Data in Brief*, vol. 3, pp. 85–89, 2015.
5. Shahid et al., "Carbon based sensors for air quality monitoring networks; middle east perspective," *Front. Chem.*, vol. 12, 2024.
6. W. Reimringer and C. Bur, "Promoting quality in low-cost gas sensor devices for real-world applications," *Frontiers in Sensors*, vol. 4, 2023.
7. 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.
8. 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.
9. S. M. Scott, D. James, and Z. Ali, "Data analysis for electronic nose systems," *Microchimica Acta*, vol. 156, no. 3, pp. 183–207, 2006.
10. 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.
11. 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.
12. 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.
13. 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.
14. G. Howard et al., "MobileNets: Efficient convolutional neural networks for mobile vision applications," *arXiv preprint arXiv:1704.04861*, 2017.
15. 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.
16. Sandler, A. Howard, M. Zhu, A. Zhmoginov, and L.-C. Chen, "MobileNetV2: Inverted residuals and linear bottlenecks," in *Proc. CVPR*, 2018, pp. 4510–4520.
17. 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.
18. 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.

19. Amiri, M. R. V. Narayana, et al., "Nanostructured metal oxide-based acetone gas sensors: A review," *Sensors*, vol. 20, no. 11, p. 3096, 2020.
20. 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.
21. 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.
22. 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.
23. 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.
24. 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.
25. 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.
26. Y. Ganin and V. Lempitsky, "Unsupervised domain adaptation by backpropagation," in *International Conference on Machine Learning (ICML)*, 2015, pp. 1180–1189.
27. B. Sun and K. Saenko, "Deep CORAL: Correlation alignment for deep domain adaptation," in *Proc. ECCV Workshops*, 2016.
28. 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.
29. 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.
30. 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.
31. Vergara et al., "Chemical gas sensor drift compensation using classifier ensembles," *Sensors and Actuators B: Chemical*, vol. 166–167, pp. 320–329, 2012.
32. Dey, "Semiconductor metal oxide gas sensors: A review," *Materials Science and Engineering: B*, vol. 229, pp. 206–217, 2018.
33. 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.
34. Barsan and U. Weimar, "Conduction model of metal oxide gas sensors," *Journal of Electroceramics*, vol. 7, no. 3, pp. 143–167, 2001.
35. 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.
36. 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.
37. 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.
38. 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.
39. 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.
40. 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.
41. S. R. Morrison, *The Chemical Physics of Surfaces*, 2nd ed. Plenum Press, 1990.
42. 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.

43. 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.
44. Z. L. Wang, "Nanostructures of zinc oxide," *Materials Today*, vol. 7, no. 6, pp. 26–33, 2004.
45. 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.
46. 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.
47. 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.
48. 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.
49. 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.
50. Rudnitskaya, "Calibration update and drift correction for electronic noses and tongues," *Frontiers in Chemistry*, vol. 6, p. 433, 2018.
51. Y. LeCun, Y. Bengio, and G. Hinton, "Deep learning," *Nature*, vol. 521, no. 7553, pp. 436-444, 2015.
52. 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.
53. G. Brereton and G. R. Lloyd, "Support vector machines for classification and regression," *Analyst*, vol. 135, no. 2, pp. 230–267, 2010.
54. 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.
55. 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.
56. 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.
57. T. Cover and J. Thomas, *Elements of Information Theory*, 2nd ed. Hoboken, NJ, USA: Wiley-Interscience, 2006.
58. 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.