

Enhancing the Reliability of Wireless Sensor Networks Using Lightweight Machine Learning

M.najafijalalieh^{*,1}, M.Shirmohammadi²

¹ Department of Computer Engineering, Hamedan Branch, Islamic Azad University, Hamedan, Iran

² Department of Computer Engineering, Hamedan Branch, Islamic Azad University, Hamedan, Iran

ABSTRACT

RESEARCH PAPER

Received: 2025-9-1

Accepted: 2025-12-2

KEYWORDS:

Wireless sensor network,
Tiny ML,
Reliability,
Fault Detection,
Internet of Things

Wireless Sensor Networks (WSNs) have emerged as one of the key technologies in recent decades due to their rapid deployability, low cost, and wide range of applications in fields such as the Internet of Things (IoT), environmental monitoring, smart agriculture, and critical systems. However, the hardware and software limitations of sensor nodes — including low processing power and limited energy resources — make these networks vulnerable to failures and disruptions, turning reliability into a fundamental challenge.

In this study, a novel framework based on Tiny Machine Learning (TinyML) is proposed to enhance reliability and optimize energy consumption in WSNs. The proposed architecture consists of four key modules — anomaly detection, failure prediction, intelligent data compression, and adaptive routing — which are deployed locally at the node level to enable fast processing, reduce communication overhead, and enable intelligent resource management.

Simulation results demonstrated that the proposed method not only increases the network lifetime and significantly reduces energy consumption but also improves data quality, communication stability, and responsiveness to abnormal events.

The findings of this research indicate that leveraging TinyML can open new horizons in the design of intelligent WSNs and provide a solid foundation for developing future large-scale applications in dynamic environments.

¹ Corresponding author:



m.najafi@iauh.ac.ir

Copyright © Author(s).



نشریه تخصصی آرمان پردازش، دوره ۶، شماره ۳، سال ۱۴۰۴



فصلنامه تخصصی آرمان پردازش
(APJ)

Homepage: www.armanprocessjournal.ir



افزایش اتکا پذیری در شبکه های حسگر بی سیم با استفاده از یادگیری ماشین کوچک

مهدی نجفی جلالیه^{۱*}، محمد مهدی شیر محمدی^۲

^۱ گروه مهندسی کامپیوتر، واحد همدان، دانشگاه آزاد اسلامی، همدان، ایران

^۲ گروه مهندسی کامپیوتر، واحد همدان، دانشگاه آزاد اسلامی، همدان، ایران

چکیده

شبکه های حسگر بی سیم (WSN) به دلیل قابلیت استقرار سریع، هزینه پایین و کاربردهای گسترده در حوزه هایی همچون اینترنت اشیا، پایش محیطی، کشاورزی هوشمند و سامانه های حیاتی، به یکی از فناوری های کلیدی در دهه های اخیر تبدیل شده اند. با این حال، محدودیت های سخت افزاری و نرم افزاری گره های حسگر، از جمله توان پردازشی و انرژی پایین، این شبکه ها را در برابر خرابی ها و اختلالات آسیب پذیر ساخته و موضوع اتکا پذیری را به چالشی اساسی بدل کرده است.

در این پژوهش، چارچوبی نوین مبتنی بر یادگیری ماشین کوچک (TinyML) برای افزایش اتکا پذیری و بهینه سازی مصرف انرژی در شبکه های حسگر بی سیم ارائه گردیده است. معماری پیشنهادی شامل چهار ماژول کلیدی تشخیص ناهنجاری، پیش بینی خرابی، فشرده سازی هوشمند داده و مسیریابی تطبیقی می باشد که با استقرار محلی در سطح گره ها، امکان پردازش سریع، کاهش بار ارتباطی و مدیریت هوشمند منابع را فراهم می سازد. نتایج شبیه سازی ها نشان داد که روش پیشنهادی علاوه بر افزایش طول عمر شبکه و کاهش چشمگیر مصرف انرژی، موجب بهبود کیفیت داده، پایداری ارتباطات و واکنش سریع به رخداد های غیر عادی می گردد.

یافته های این تحقیق نشان می دهد که بهره گیری از یادگیری ماشین کوچک می تواند افق های جدیدی را در طراحی شبکه های حسگر بی سیم هوشمند بگشاید و بستر مناسبی برای توسعه کاربردهای آینده در مقیاس های کلان و محیط های پویا فراهم آورد.


مقاله پژوهشی

واژگان کلیدی:

شبکه حسگر بی سیم،
یادگیری ماشین کوچک،
اتکا پذیری،
تشخیص خطا،
اینترنت اشیا.

۱- مقدمه

شبکه‌های حسگر بی‌سیم (Wireless Sensor Networks - WSNs)، به عنوان یکی از فناوری‌های کلیدی در حوزه اینترنت اشیا (IoT)، در سال‌های اخیر به طور گسترده‌ای مورد توجه قرار گرفته‌اند. این شبکه‌ها متشکل از تعداد زیادی گره حسگر با توان پردازشی، ذخیره‌سازی و ارتباطی محدود هستند که در محیط‌های مختلف برای پایش محیطی، کنترل هوشمند، مدیریت انرژی، کشاورزی دقیق و سلامت از راه دور به کار می‌روند. گره‌های حسگر پس از جمع‌آوری اطلاعات، آن‌ها را به یک گره مرکز یا ایستگاه پایه ارسال می‌کنند تا مورد تحلیل قرار گیرند. با توجه به ماهیت بی‌سیم، مصرف انرژی محدود و قرارگیری در محیط‌های نامساعد و غیرقابل کنترل، حفظ اتکاپذیری (Reliability) در این شبکه‌ها به یکی از چالش‌های اصلی و حیاتی تبدیل شده است.



شکل ۱: نمایی از شبکه سنسور بی‌سیم

اتکاپذیری در شبکه‌های WSN، به توانایی سیستم برای ارائه خدمات پیوسته، دقیق و بدون خطا در مواجهه با اختلالات گوناگون اشاره دارد. این اختلالات می‌توانند شامل خرابی گره‌ها، قطع ارتباط به دلیل موانع فیزیکی یا تداخلات محیطی، داده‌های نادرست ناشی از حسگرهای معیوب و یا حملات امنیتی باشند. از دست رفتن اتکاپذیری می‌تواند منجر به داده‌های ناقص، کاهش دقت در تصمیم‌گیری‌ها و حتی شکست کامل وظایف محوله شود. از این رو، طراحی و پیاده‌سازی سازوکارهایی که بتوانند خطاها را تشخیص دهند، با شرایط ناپایدار شبکه سازگار شوند و عملکرد کلی سیستم را حفظ کنند، ضروری است (1).

در سال‌های اخیر، استفاده از الگوریتم‌های یادگیری ماشین (Machine Learning - ML) به عنوان ابزاری قدرتمند برای تحلیل داده‌ها، تشخیص الگو و پیش‌بینی رفتار سیستم‌ها مطرح شده است. این الگوریتم‌ها می‌توانند به افزایش خودمختاری سیستم‌های توکار (Embedded Systems) کمک کنند. با این حال، اجرای مستقیم مدل‌های پیچیده ML بر روی گره‌های حسگر با محدودیت‌های جدی مانند توان پردازشی پایین، مصرف انرژی محدود و حافظه اندک مواجه است. علاوه بر این، انتقال حجم زیاد داده‌های خام از گره‌ها به سرور مرکزی برای پردازش، پهنای باند شبکه را به شدت اشغال کرده و موجب افزایش مصرف انرژی می‌شود (2).

در پاسخ به این محدودیت‌ها، حوزه نوظهور یادگیری ماشین کوچک یا TinyML شکل گرفته است. این فناوری به توسعه و پیاده‌سازی مدل‌های یادگیری ماشین سبک، کم‌حجم و بهینه‌شده برای اجرا بر روی سخت‌افزارهای کم‌مصرف، مانند میکروکنترلرها (MCUs)، می‌پردازد. TinyML به گره‌های حسگر امکان می‌دهد تا تحلیل‌های محلی و تصمیم‌گیری‌های بی‌درنگ انجام دهند و تنها در صورت لزوم اطلاعات مهم را به ایستگاه مرکزی منتقل کنند. از این طریق می‌توان تا حد زیادی در مصرف انرژی صرفه‌جویی کرد، تأخیر در پردازش را کاهش داد، حریم خصوصی داده‌ها را افزایش داد و عملکرد شبکه را پایدارتر نمود. این قابلیت‌ها به ویژه در سناریوهایی که نیاز به پاسخ‌دهی سریع و تحلیل آفلاین داده‌ها وجود دارد، بسیار حیاتی هستند (3).

با وجود اهمیت TinyML، تحقیقات فعلی در زمینه کاربرد آن برای افزایش اتکاپذیری WSN هنوز کامل نیست. بیشتر مدل‌های موجود تنها برای پیش‌بینی یا طبقه‌بندی کاربرد دارند و کمتر به موضوعات پیچیده‌تر مانند تشخیص آنومالی، مسیریابی تطبیقی و نگهداری پیش‌بینانه با اجرای محلی پرداخته‌اند. پژوهش‌های پیشین به صورت جداگانه بر روی هر یک از این حوزه‌ها تمرکز کرده‌اند، اما یک چارچوب عملی و جامع که بتواند این قابلیت‌ها را در یک معماری یکپارچه پیاده‌سازی کند، هنوز ارائه نشده است. این شکاف در پژوهش‌های موجود، انگیزه اصلی ما برای انجام این تحقیق است (4). در این مقاله، ما به دنبال ارائه یک معماری عملی مبتنی بر TinyML برای افزایش اتکاپذیری شبکه‌های حسگر بی‌سیم هستیم. معماری پیشنهادی ما شامل ماژول‌های تشخیص ناهنجاری برای شناسایی داده‌های غیرمعمول، پیش‌بینی خطا برای تشخیص زود هنگام مشکلات احتمالی، فشرده‌سازی هوشمند داده‌ها برای کاهش حجم داده‌های ارسالی و مسیریابی تطبیقی برای مدیریت بهینه جریان داده است. تمامی این ماژول‌ها برای پیاده‌سازی بر روی گره‌های حسگر سبک طراحی شده‌اند. هدف ما این است که نشان دهیم چگونه یک رویکرد یکپارچه مبتنی بر TinyML می‌تواند عملکرد کلی شبکه را در شرایط نامطمئن و با منابع محدود به طور قابل توجهی بهبود بخشد. کارایی این روش‌ها با تکیه بر نتایج شبیه‌سازی یا نمونه‌سازی اولیه بررسی و ارزیابی خواهد شد.

ساختار این مقاله به شرح زیر است: در بخش دوم، مروری بر پژوهش‌های پیشین و مفاهیم کلیدی مرتبط با WSN، TinyML و اتکاپذیری ارائه می‌شود. بخش سوم، به شرح معماری و روش پیشنهادی ما می‌پردازد. در بخش چهارم، نتایج ارزیابی عملکرد و تحلیل آن‌ها آورده شده و در نهایت، در بخش پنجم، جمع‌بندی و پیشنهاداتی برای پژوهش‌های آتی ارائه خواهد شد.

۲- بیان مسئله

شبکه های حسگر بی سیم (WSN) به دلیل قابلیت استقرار سریع، هزینه پایین، و انعطاف پذیری بالا، به طور گسترده در محیط های نامطمئن، غیرقابل دسترس یا حساس به انرژی مورد استفاده قرار می گیرند. با این حال، گره های حسگر در این شبکه ها اغلب از منابع محدودی از جمله پردازنده ضعیف، حافظه اندک، و باتری با ظرفیت محدود بهره مند هستند. این محدودیت ها سبب می شود که عملکرد این شبکه ها در برابر عوامل اختلال زا مانند خرابی گره ها، ناپایداری ارتباطات، خطاهای حسگر، یا حملات امنیتی به شدت آسیب پذیر باشد. چنین ضعف هایی، منجر به کاهش اتکا پذیری (Reliability) شبکه و تضعیف کیفیت خدمات آن در کاربردهای حیاتی می شود.

روش های سنتی برای افزایش اتکا پذیری، معمولاً متکی بر الگوریتم های متمرکز و ارسال داده های حسگر به ایستگاه پایه جهت تحلیل و تصمیم گیری هستند. این روش ها نه تنها با تأخیر بالا و مصرف انرژی زیاد همراه اند، بلکه در صورت قطعی ارتباط یا ازدحام شبکه، به کلی از کار می افتند. از سوی دیگر، استفاده از الگوریتم های یادگیری ماشین برای شناسایی خطا و پیش بینی اختلالات نیز با چالش هایی جدی در محیط های دارای محدودیت منابع مواجه است؛ چرا که مدل های ML معمولاً نیاز به منابع محاسباتی و ذخیره سازی بالایی دارند.

در چنین شرایطی، استفاده از یادگیری ماشین کوچک (TinyML) به عنوان راهکاری نوظهور برای اجرای مدل های سبک یادگیری ماشین در سخت افزارهای کم مصرف، می تواند راه حلی مناسب برای افزایش هوشمندی و پایداری گره های حسگر باشد. با استقرار مدل های یادگیری سبک در گره های شبکه، امکان تصمیم گیری محلی، تشخیص سریع خطاها، و بهبود سازگاری شبکه با شرایط متغیر فراهم می شود، بدون آنکه به ارتباط مداوم با سرور مرکزی نیاز باشد.

مسئله اصلی که این پژوهش به آن می پردازد، چگونگی طراحی و پیاده سازی معماری مبتنی بر TinyML برای بهبود اتکا پذیری شبکه های حسگر بی سیم است، به گونه ای که با وجود محدودیت منابع، بتوان دقت، پایداری و طول عمر شبکه را افزایش داد. این پژوهش در تلاش است تا نشان دهد چگونه مدل های بهینه شده یادگیری ماشین می توانند به صورت مؤثر در لبه شبکه پیاده سازی شده و عملکرد سیستم را در برابر خطا و اختلال بهبود بخشند.

۳- کارهای مرتبط

شبکه های حسگر بی سیم (WSN) متشکل از تعداد زیادی گره حسگر با توان پردازشی، ارتباطی و ذخیره سازی محدود هستند که در محیط های مختلف برای پایش داده به کار می روند. یکی از چالش های اصلی در این شبکه ها، اتکا پذیری پایین در برابر خرابی گره ها، قطع ارتباط، یا تداخلات محیطی است. پژوهش (8) نشان داده است که ویژگی هایی مانند مصرف انرژی کم، تحمل خطا، و مدیریت مسیر، در طراحی WSN اهمیت

کلیدی دارند و راهکارهای سنتی همچون الگوریتم های مسیریابی یا افزونگی داده نمی توانند به تنهایی عملکرد پایدار شبکه را تضمین کنند. TinyML به عنوان حوزه ای نوظهور در یادگیری ماشین، امکان اجرای مدل های سبک و بهینه شده بر روی دستگاه های بسیار محدود مانند میکروکنترلرها را فراهم می سازد. طبق مرور (2) در حوزه هایی مانند کشاورزی هوشمند، پایش محیط، تشخیص ناهنجاری، و اینترنت حیوانات به کار گرفته شده و قابلیت هایی مانند مصرف انرژی بسیار پایین، زمان پاسخ سریع، حفظ حریم خصوصی داده ها و اجرای آفلاین را ارائه می دهد.

یکی از مسیرهای نوین پژوهش، استفاده از TinyML در گره های WSN برای انجام تحلیل های محلی و تصمیم گیری بی درنگ است. پژوهش (4) در مقاله ای در مجله *Information Fusion*، ترکیب یادگیری فدرال (Federated Learning) و یادگیری انتقالی (Transfer Learning) را برای آموزش مدل های TinyML درون گرا (on-board) پیشنهاد داده است. آن ها با آزمایش روی دستگاه های واقعی مثل *Arduino* و *Raspberry Pi* نشان دادند که این رویکرد می تواند دقت پیش بینی را افزایش داده، مصرف انرژی را کاهش دهد و در شرایط داده های نامتوازن نیز عملکرد مطلوبی داشته باشد.

این روش با حذف نیاز به ارسال داده های خام به سرور مرکزی، نه تنها مصرف انرژی و پهنای باند را کاهش می دهد بلکه به افزایش پایداری و اتکا پذیری شبکه کمک می کند. همچنین، وجود چارچوب هایی مانند *TensorFlow Lite Micro* و *TinyTrain* زمینه را برای آموزش و استقرار مدل ها روی گره های بسیار سبک فراهم ساخته است.

یکی از مطالعات اولیه در زمینه امنیت شبکه های حسگر بی سیم، توسط (5) ارائه شده است. در این پژوهش، نویسندگان با بررسی کاربردهای گسترده WSN در حوزه های نظامی، پزشکی، محیط زیست و صنعت، بر چالش های امنیتی ناشی از ماهیت بی سیم شبکه و محدودیت منابع نودها تأکید کرده اند. در این مقاله انواع حملات مهم مانند *DoS*، *Hello Flood*، *Selective Forwarding*، *Sinkhole*، *Sybil*، *Wormhole* و *Node Capture* و حملات مبتنی بر درج نود مخرب تحلیل شده و راهکارهای مقابله ای متناسب با هر لایه از شبکه ارائه گردیده است. تمرکز ویژه این مطالعه بر حملات *DoS* و پیامدهای آن بر کاهش توان عملیاتی شبکه بوده است. همچنین نویسندگان پیشنهاد کرده اند که به جای راهکارهای جزیره ای در هر لایه، لازم است رویکردهای یکپارچه امنیتی توسعه داده شود تا بتوان امنیت WSN را به صورت کلی تضمین کرد

در حوزه امنیت شبکه های حسگر بی سیم، پژوهش جامعی توسط (6) انجام شده است که در آن تهدیدات امنیتی متنوع همچون حملات *DoS*، *Sinkhole*، *Sybil*، *Wormhole* و *Selective Forwarding* مورد بررسی قرار گرفته و برای هر یک از این تهدیدات، مکانیزم های دفاعی متناسب معرفی شده است. این مطالعه با مرور طیف وسیعی از الگوریتم ها و پروتکل های موجود، از جمله روش های رمزنگاری، توزیع کلید، احراز هویت چندعاملی و سامانه های تشخیص نفوذ، تصویری

سخت‌افزارهای تخصصی را برجسته می‌کنند. این مقاله همچنین چارچوب‌ها و کتابخانه‌های موجود مانند TensorFlow Lite را مورد بررسی قرار داده و نقش آن‌ها را در گسترش کاربرد یادگیری ماشین در دستگاه‌های تعبیه‌شده توضیح می‌دهد.

این تحقیق کاربردهای TinyML را در زمینه‌های مختلفی از جمله نظارت بر محیط زیست، ردیابی افراد، و تشخیص ناهنجاری بررسی می‌کند. این مقاله نشان می‌دهد که چگونه TinyML با پردازش داده‌ها در نزدیکی سنسورها، حریم خصوصی و پاسخگویی را افزایش داده و در عین حال هزینه‌های مرتبط با انتقال داده بی‌سیم را کاهش می‌دهد. این مقاله یک منبع اطلاعاتی مهم برای جامعه پژوهش اینترنت اشیا و رایانش ابری است و می‌تواند راه را برای مطالعات آینده در این زمینه هموار کند.

با پیشرفت الگوریتم‌های یادگیری ماشین، پژوهشگران تلاش کرده‌اند از آن‌ها برای افزایش هوشمندی WSN استفاده کنند؛ از جمله در کاربردهایی مانند تشخیص خطا، پیش‌بینی عمر باتری، و طبقه‌بندی رویدادها. با این حال، اجرای این الگوریتم‌ها در محیطی با منابع محدود مانند گره‌های WSN چالش برانگیز است، زیرا اغلب مدل‌ها نیازمند منابع محاسباتی، انرژی و حافظه بالا هستند.

اگرچه پژوهش‌های متعددی به بررسی TinyML و یادگیری ماشین در IoT و WSN پرداخته‌اند، اما هنوز چارچوب‌های عملی و جامعی برای افزایش اتکاپذیری WSN با استفاده مستقیم از TinyML در سطح گره‌های حسگر توسعه نیافته است. بیشتر مدل‌های موجود تنها برای پیش‌بینی یا طبقه‌بندی کاربرد دارند و کمتر به موضوعاتی مانند تشخیص آنومالی، مسیریابی تطبیقی و نگهداری پیش‌بینانه با اجرای محلی پرداخته‌اند. مقاله حاضر تلاش دارد این شکاف را با ارائه یک معماری کاربردی پوشش دهد.

جدول مقایسه کارهای مرتبط

جدول ۱: مقایسه کارهای مرتبط

مرجع	موضوع اصلی	نکات کلیدی	نقاط قوت/تمرکز
García-Hernández et al. (2007)	اتکاپذیری در شبکه‌های WSN	بررسی چالش‌های اتکاپذیری و نقش تحمل خطا و مصرف انرژی کم	تأکید بر عدم کفایت راهکارهای سنتی
Kalpna Sharma (2010)	امنیت در شبکه‌های WSN	تحلیل حملات رایج مانند Sybil و DoS	بررسی اولیه حملات و ارائه راهکارهای لایه‌ای
Schizas et al. (2022)	مرور جامع TinyML	بررسی چالش‌های TinyML (حافظه و قدرت پردازش محدود) و چارچوب‌های آن (TensorFlow Lite)	مرور سیستماتیک بر TinyML و چالش‌های ساخت‌افزایی آن
Abadade et al. (2023)	کاربرد IoT TinyML	ارائه کاربردهای TinyML در زمینه‌های مختلف (کشاورزی هوشمند)	تأکید بر مزایای TinyML مانند پاسخ سریع و حفظ حریم خصوصی
Ficco et al. (2024)	WSN TinyML	پیشنهاد ترکیب یادگیری فدرال و انتقالی برای افزایش دقت و کاهش مصرف انرژی	رویکرد نوین برای پیاده‌سازی TinyML در سطح گره‌های حسگر
Moslehi et al. (2025)	پوشش و امنیت WSN	بررسی استراتژی‌های استقرار و راهکارهای امنیتی مبتنی بر یادگیری ماشین	ارائه یک مرور جامع بر هر دو جنبه پوشش و امنیت
Elham Alotaibi et al. (2025)	امنیت پیشرفته WSN	بررسی تهدیدات متنوع و مکانیزم‌های دفاعی (رمزنگاری، احراز هویت)	مرور جامع بر مکانیزم‌های امنیتی در WSN

جامع از وضعیت امنیتی WSN ارائه کرده است. نویسندگان همچنین چالش‌های باقی‌مانده و نیاز به توسعه راهکارهای کارآمدتر و سبک‌تر برای مقابله با حملات نوظهور را برجسته کرده‌اند.

مقاله «Exploring coverage and security challenges in wireless sensor networks: A survey» (Moslehi et al. (2025) (14) به بررسی جامعی از چالش‌های پوشش و امنیت در شبکه‌های حسگر بی‌سیم می‌پردازد. این مقاله استراتژی‌های استقرار مختلف مانند روش‌های قطعی، تصادفی و سه‌بعدی را تحلیل کرده و تأثیر آن‌ها بر پوشش، اتصال و مصرف انرژی را بررسی می‌کند. همچنین، این پژوهش به چالش‌های امنیتی کلیدی مانند حملات DoS، حملات black-hole و gray-hole، و همچنین راه‌حل‌های مربوط به آن‌ها مانند سیستم‌های تشخیص نفوذ (IDS) مبتنی بر یادگیری ماشین و تکنیک‌های الهام گرفته از زیست می‌پردازد. این مقاله با مقایسه شبکه‌های حسگر همگن و ناهمگن، نشان می‌دهد که چگونه معیارهای متفاوت طراحی بر عملکرد و امنیت شبکه تأثیر می‌گذارند. بنابراین، این مقاله یک منبع ارزشمند برای درک مسائل پیچیده در زمینه استقرار و امنیت WSN است و می‌تواند به عنوان یک پایه نظری محکم برای پژوهش‌های مرتبط مورد استفاده قرار گیرد. مقاله «TinyML for Ultra-Low Power AI and Large Scale IoT Deployments: A Systematic Review» (Schizas و همکاران (۲۰۲۲) یک مرور جامع بر TinyML ارائه می‌دهد. این پژوهش TinyML را به عنوان یک حوزه فناوری نوظهور معرفی می‌کند که هدف آن پیاده‌سازی الگوریتم‌های یادگیری ماشین بر روی دستگاه‌های با منابع محدود و میکروکنترلرها (MCUs) است. این فناوری با کاهش تأخیر، مصرف بهینه پهنای باند و بهبود امنیت و حریم خصوصی داده‌ها، عصر جدیدی را در اینترنت اشیا (IoT) رقم می‌زند. (25) این مقاله به بررسی چالش‌های کلیدی TinyML، از جمله مصرف انرژی بسیار پایین، حافظه محدود، قدرت پردازش و ناهمگونی سخت‌افزار می‌پردازد. نویسندگان توضیح می‌دهند که چگونه این محدودیت‌ها بر عملکرد سیستم تأثیر می‌گذارند و نیاز به الگوریتم‌های بهینه‌سازی و

۴- پروتکل پیشنهادی

در این پژوهش، با هدف افزایش اتکا پذیری در شبکه های حسگر بی سیم، یک چارچوب نوین مبتنی بر یادگیری ماشین کوچک ارائه شده است که قادر است فرایندهای تصمیم گیری و تحلیل داده را به سطح گره های حسگر انتقال دهد. رویکرد سنتی مبتنی بر ارسال همه داده ها به ایستگاه مرکزی نه تنها مصرف انرژی را افزایش می دهد، بلکه در مواجهه با اختلالات شبکه (مانند قطع ارتباط یا تداخل)، باعث از دست رفتن داده یا تأخیر در واکنش سیستم می شود. در چارچوب پیشنهادی، هر گره حسگر به یک مدل یادگیری سبک مجهز شده که پس از آموزش خارج از شبکه (offline)، به فرمت فشرده درآمده و بر روی میکروکنترلر گره مستقر می گردد. این مدل می تواند در محل (on-device) وظایفی نظیر تشخیص ناهنجاری، پیش بینی خرابی گره، و تصمیم گیری درباره ارسال یا عدم ارسال داده را برعهده بگیرد.

ایده اصلی این معماری بر این مبنا است که گره های حسگر، علی رغم محدودیت های جدی از نظر پردازش، حافظه و انرژی، می توانند با بهره گیری از مدل های یادگیری ماشین سبک، قابلیت های هوشمندانه ای در خود جای دهند. به جای تکیه صرف بر روش های سنتی مسیریابی یا مکانیزم های امنیتی که عمدتاً به صورت مجزا عمل می کنند، این معماری به دنبال آن است که چندین قابلیت کلیدی را در قالب یک راهکار منسجم و هماهنگ ترکیب نماید.

تمرکز اصلی این رویکرد بر طراحی ماژول های سبک و کارآمد است که بتوانند بدون ایجاد سربار سنگین محاسباتی یا مصرف انرژی بیش از حد، روی گره های کم منبع اجرا شوند. معماری پیشنهادی علاوه بر آنکه به نیازهای عملیاتی WSN پاسخ می دهد، با شرایط نامطمئن محیطی و محدودیت های ذاتی این شبکه ها نیز سازگار است.

این معماری با ادغام چهار ماژول اصلی یعنی تشخیص ناهنجاری، پیش بینی خطا، فشرده سازی هوشمند داده و مسیریابی تطبیقی، قادر است هم زمان چندین جنبه ی مهم از عملکرد شبکه را بهبود بخشد: کیفیت داده ها از طریق حذف یا علامت گذاری داده های غیرعادی ارتقا می یابد؛ پایداری شبکه با پیش بینی خرابی ها و فعال سازی مسیرهای جایگزین تضمین می شود؛ بهره وری انرژی از طریق کاهش داده های ارسالی افزایش می یابد؛ و در نهایت، مدیریت جریان داده با انتخاب پویا و هوشمند مسیرهای ارتباطی بهینه صورت می گیرد.

به بیان دیگر، هدف اصلی این معماری آن است که نشان دهد چگونه می توان با حداقل مصرف منابع سخت افزاری و نرم افزاری، حداکثر میزان پایداری، دقت و کارایی را در شبکه های حسگر بی سیم فراهم آورد. این رویکرد نه تنها امکان افزایش طول عمر شبکه را فراهم می سازد، بلکه بهبود کیفیت سرویس و اطمینان پذیری داده ها را نیز تضمین می کند.

معماری پیشنهادی

معماری پیشنهادی شامل چهار ماژول اصلی است که به صورت مکمل با یکدیگر عمل می کنند:

1. ماژول تشخیص ناهنجاری (Anomaly Detection)

در شبکه های حسگر، داده های جمع آوری شده همواره قابل اعتماد نیستند و ممکن است به دلیل نویز، خرابی سخت افزار یا حملات مخرب دچار انحراف شوند. این ماژول با استفاده از مدل های سبک TinyML داده ها را به صورت بلادرنگ تحلیل کرده و مقادیر غیرمعمول را شناسایی می کند. داده های ناهنجار بلافاصله علامت گذاری شده و با اولویت بالا در شبکه ارسال می شوند تا امکان واکنش سریع فراهم گردد. این قابلیت نه تنها کیفیت داده های جمع آوری شده را بهبود می بخشد، بلکه مانع از انتشار داده های بی ارزش یا مضر در شبکه می شود.

2. ماژول پیش بینی خطا (Fault Prediction)

یکی از نقاط ضعف WSN، خرابی ناگهانی گره ها یا لینک های ارتباطی است که می تواند منجر به از دست رفتن داده ها یا قطع سرویس گردد. ماژول پیش بینی خطا با تحلیل شاخص های سلامت گره ها (مانند انرژی باقی مانده، دما، کیفیت لینک و نرخ از دست رفت بسته ها) احتمال خرابی آینده را تخمین می زند. در صورت پیش بینی خطر خرابی، گره مربوطه می تواند به طور خودکار داده های خود را تخلیه کرده یا مسیرهای جایگزین را فعال کند. این امر سبب می شود که اختلالات شبکه به حداقل برسد و زمان بازیابی کاهش یابد.

3. ماژول فشرده سازی هوشمند داده (Smart Data Compression)

ارسال داده به عنوان یکی از پرمصرف ترین عملیات ها در گره های حسگر، سهم زیادی در مصرف انرژی دارد. ماژول فشرده سازی هوشمند داده با بهره گیری از الگوریتم های سبک و تطبیقی، داده ها را بر اساس میزان تغییر پذیری آن ها فشرده می کند. برای داده های پایدار، از روش های ساده استفاده می شود، در حالی که برای داده های پرنوسان یا حیاتی، روش های دقیق تر با خطای کمتر به کار گرفته می شوند. این سازوکار سبب کاهش چشمگیر حجم ترافیک شبکه شده و در نتیجه طول عمر گره ها و کل شبکه افزایش می یابد.

4. ماژول مسیریابی تطبیقی (Adaptive Routing)

به منظور تضمین تحویل داده در شرایط متغیر شبکه، ماژول مسیریابی تطبیقی طراحی شده است. این ماژول با ارزیابی مداوم معیارهایی نظیر کیفیت لینک، میزان ترافیک، تأخیر و سطح اعتماد به همسایه ها، مسیر بهینه را برای ارسال داده انتخاب می کند. در شرایط بحرانی، مانند وقوع خطا یا شناسایی ناهنجاری، مسیرهای جایگزین فعال می شوند تا از اختلال در سرویس جلوگیری شود. این ویژگی پایداری و قابلیت اعتماد شبکه را به شکل قابل توجهی ارتقا می دهد.

ویژگی های کلیدی معماری

یکپارچگی: ترکیب چهار ماژول فوق در قالب یک معماری هماهنگ، امکان مدیریت جامع اتکا پذیری شبکه را فراهم می سازد. سبک و بهینه: تمامی مدل ها و الگوریتم ها به گونه ای طراحی شده اند که روی گره های کم منبع با حداقل توان پردازشی قابل اجرا باشند.

$$(4) \quad e_i = |x_i - \hat{x}_i|$$

اگر این خطا از آستانه تجربی θ بیشتر باشد، داده به عنوان ناهنجاری در نظر گرفته می‌شود:

$$(5) \quad \text{Label}_i = \begin{cases} 1 & \theta < e_i \text{ (ناهنجاری)} \\ 0 & \text{در غیر این صورت} \end{cases}$$

۴. مدل مصرف انرژی گره
برای بررسی کارایی روش پیشنهادی، مدل مصرف انرژی به صورت زیر تعریف می‌شود:

$$(6) \quad E_{\text{total}} = E_{\text{tx}} \cdot N_{\text{tx}} + E_{\text{comp}} \cdot N_{\text{inf}}$$

که در آن:

جدول ۲: پارامترهای فرمول

نماد	توضیح	واحد
E_{tx}	انرژی ارسال هر بسته (مثلاً ۵۰۰۰ nJ)	nJ
N_{tx}	تعداد بسته‌های ارسالی به ایستگاه مرکزی	عدد صحیح
E_{comp}	inference انرژی هر بار اجرای	nJ
N_{inf}	دفعات اجرای مدل روی داده	عدد صحیح
E_{total}	انرژی کل مصرف شده توسط گره	nJ یا mJ

۵. پیش‌بینی خرابی گره (در صورت داده کافی)
برای جلوگیری از خاموشی ناگهانی گره، می‌توان از یک مدل طبقه‌بندی ساده (مثلاً Logistic Regression) برای پیش‌بینی خرابی استفاده کرد. ورودی مدل برداری از ویژگی‌ها مانند ولتاژ، دما و نرخ افت بسته است:

$$X = [\text{Voltage} \ \text{PacketLossRate} \ \text{Temperature}] \quad (7)$$

تابع تصمیم مدل به صورت:

$$P(\text{Failure}) = \sigma(w^T X + b) = \frac{1}{1 + e^{-(w^T X + b)}} \quad (8)$$

که اگر مقدار خروجی بیش از ۰/۵ باشد، گره در معرض خرابی تشخیص داده می‌شود.

جدول ۳: نمادها و پارامترهای استفاده شده در فرمول‌های پروتکل پیشنهادی

نماد	توضیح	واحد
x	مقدار خام داده حسگر	C^0
x_{norm}	مقدار نرمال شده	بدون واحد
\hat{x}	مقدار بازسازی شده	مشابه x
E_i	خطای بازسازی	مشابه x
θ	آستانه تشخیص ناهنجاری	مشابه e_i
E_{tx}	انرژی ارسال یک بسته	nJ
N_{tx}	تعداد بسته‌های ارسالی	عدد صحیح
E_{comp}	انرژی محاسبه inference	nJ
N_{inf}	تعداد اجرای مدل	عدد صحیح

تطبيق پذیری: مازول‌ها به صورت پویا بر اساس شرایط محیطی و شبکه تنظیم می‌شوند.

صرفه‌جویی انرژی: کاهش ترافیک غیرضروری و جلوگیری از ارسال داده‌های بی‌ارزش، به طور مستقیم منجر به افزایش طول عمر شبکه می‌شود.

معماری سیستم شبکه سنسور بی‌سیم شامل دو لایه اصلی است:

۱. گره‌های حسگر هوشمند: شامل حسگر، میکروکنترلر کم‌مصرف، و مدل یادگیری.

۲. ایستگاه پایه: دریافت‌کننده داده‌های نهایی و هشدارها.

هر گره پس از دریافت داده از حسگر، ابتدا آن را نرمال‌سازی کرده و سپس مدل محلی را برای تحلیل داده اجرا می‌کند. در صورت شناسایی ناهنجاری، بسته اطلاعاتی حاوی داده و هشدار به ایستگاه مرکزی ارسال می‌شود. در غیر این صورت، داده حذف یا فشرده شده و تنها در صورت نیاز ارسال می‌گردد.

همچنین، در نسخه توسعه‌یافته این چارچوب، یک مازول ساده برای مدل‌سازی مصرف انرژی و پیش‌بینی زوال عملکرد گره‌ها نیز افزوده شده است تا از طریق تحلیل وضعیت گره، امکان نگهداری پیشگیرانه فراهم گردد.

این روش موجب می‌شود:

از ارسال غیرضروری داده‌ها جلوگیری شود،

مصرف انرژی کاهش یابد،

واکنش سریع به رخدادهای مهم در محل انجام شود،

و طول عمر عملیاتی شبکه افزایش یابد.

مراحل گام‌به‌گام

۱. تولید و نرمال‌سازی داده‌ها

داده‌های حسگر (مثلاً دما، رطوبت) به صورت مصنوعی یا واقعی جمع‌آوری شده و برای ورود به مدل یادگیری نرمال‌سازی می‌شوند:

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

۲. آموزش مدل Autoencoder

از یک مدل Autoencoder سبک برای یادگیری الگوی نرمال داده استفاده می‌شود. مدل تلاش می‌کند ورودی x را بازسازی کند:

$$(2) \quad \hat{x} = f_{\text{decoder}}(f_{\text{encoder}}(x))$$

و تابع زیان مدل به صورت میانگین مربع خطای بازسازی است:

$$(3) \quad \iota = \frac{1}{n} \sum_{i=1}^n (x_i - \hat{x}_i)^2$$

۳. تشخیص ناهنجاری (Anomaly Detection)

پس از آموزش، برای هر داده ورودی، خطای بازسازی محاسبه می‌شود:

خارج از گره و یکبار برای همیشه انجام شده، سپس مدل در قالب فشرده بر روی گره بارگذاری می شود.

۴. محاسبه خطای بازسازی

هنگامی که داده جدیدی توسط گره دریافت می شود، مدل یادگیری تلاش می کند آن داده را بازسازی کند. میزان اختلاف بین داده اصلی و بازسازی شده اندازه گیری می شود تا مشخص شود آیا این داده مطابق الگوهای نرمال است یا خیر.

۵. تشخیص ناهنجاری

در این مرحله، تصمیم گیری انجام می شود که آیا داده ای که دریافت شده، رفتاری غیرعادی دارد یا خیر. اگر مدل یادگیری آن را مشابه الگوهای معمول تشخیص ندهد، گره آن را به عنوان ناهنجاری شناسایی کرده و به ایستگاه مرکزی ارسال می کند. در غیر این صورت، از ارسال آن صرف نظر می شود.

۶. برآورد مصرف انرژی

با توجه به تعداد دفعات پردازش و میزان داده های ارسال شده، میزان مصرف انرژی گره برای این دوره عملکرد برآورد می شود. این برآورد به ما کمک می کند تا میزان بهینه سازی انرژی در روش پیشنهادی را نسبت به روش های سنتی بسنجیم.

۷. پیش بینی خرابی گره

در این مرحله، با بررسی برخی ویژگی های فنی مانند افت ولتاژ، دمای بالا یا ضعف در برقراری ارتباط، یک مدل یادگیری دیگر بررسی می کند که آیا گره در معرض خرابی یا خاموشی قریب الوقوع قرار دارد یا خیر. در صورت مثبت بودن پیش بینی، هشدار لازم ارسال می شود.

۸. پایان

پس از اتمام پردازش و ارسال (در صورت لزوم)، گره به وضعیت آماده باش بازمی گردد و منتظر داده بعدی می ماند.

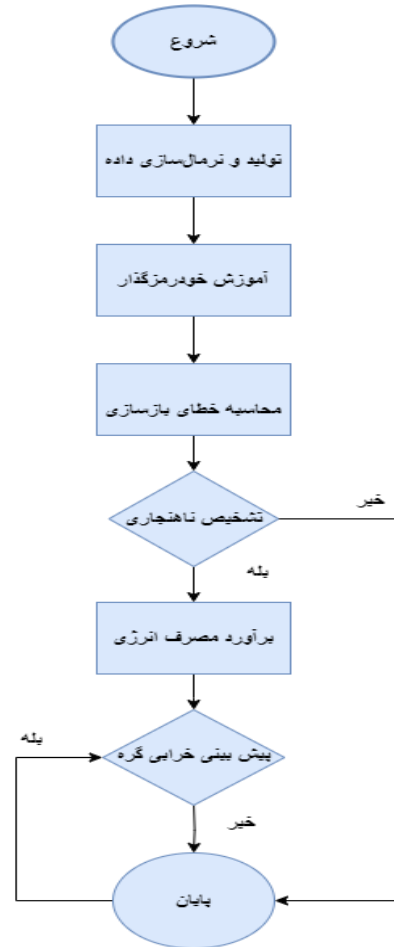
۵- شبیه سازی پروتکل

برای ارزیابی عملکرد پروتکل پیشنهادی، شبیه سازی کامپیوتری در محیط MATLAB انجام شد. هدف اصلی این شبیه سازی بررسی مصرف انرژی، کارایی انتقال داده و پایداری شبکه در طول زمان است. پارامترهای اصلی مانند تعداد نودها، تعداد خوشه ها، مکان استگاه پایه (BS)، و میزان انرژی اولیه نودها تعریف شده اند. همچنین روش انتخاب سرخوشه ها، فشرده سازی داده و انتقال چندمرحله ای برای بهبود مصرف انرژی در نظر گرفته شده است (شکل ۱).

P(Failure)	احتمال خرابی گره	[0,1]
------------	------------------	-------

فلوچارت پروتکل پیشنهادی

فلوچارت کامل این فرآیند در شکل زیر نمایش داده شده است:



شکل ۲: فلوچارت

توضیح مراحل فلوچارت روش پیشنهادی

۱. شروع

فرآیند تحلیل داده در گره حسگر آغاز می شود. فرض بر این است که گره مجهز به حسگر، میکروکنترلر و مدل یادگیری از قبل آموزش دیده می باشد.

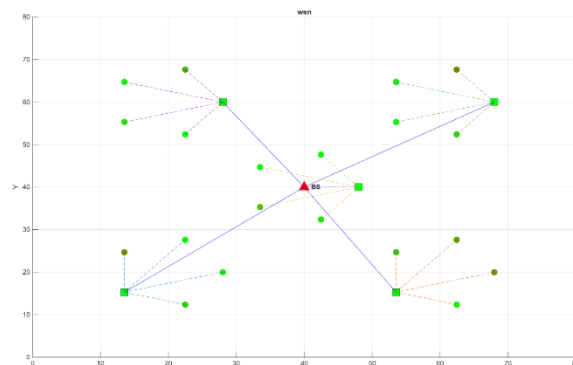
۲. تولید و نرمال سازی داده

در این مرحله، داده های خام از حسگر (مانند دما، رطوبت یا ولتاژ باتری) دریافت شده و به مقیاس استاندارد تبدیل می شوند تا برای ورود به مدل یادگیری مناسب باشند. این مرحله باعث افزایش دقت پردازش مدل و کاهش حساسیت آن نسبت به نوسانات غیرمؤثر می شود.

۳. آموزش خودرمزگذار

در این بخش، مدل یادگیری که از نوع خودرمزگذار یا Autoencoder است، با استفاده از داده های سالم و نرمال آموزش داده می شود. هدف از آموزش، یادگیری الگوی رفتاری معمول داده ها است. این آموزش معمولاً

۳. مسیریابی تطبیقی: اگر فاصله سرخوشه تا (BS) بیشتر از آستانه تعیین شده بود، مسیر ارسال داده از طریق یک سرخوشه دیگر با انرژی کافی به عنوان رله انتخاب می شد. این مکانیزم باعث بهبود پایداری شبکه و کاهش مصرف انرژی کل می گردد.
۴. به روزرسانی انرژی و ثبت داده ها: انرژی باقی مانده نودها پس از هر راند ثبت شد و تعداد نودهای مرده محاسبه گردید.



شکل ۳: مختصات شبکه حسگر بی سیم

الگوریتم خوشه بندی و انتخاب سرخوشه با استفاده از (K-means)

در این مدل، خوشه بندی نودهای شبکه با استفاده از الگوریتم مشهور k-means انجام شده است. الگوریتم k-means یکی از روش های یادگیری بدون نظارت برای تقسیم داده ها به (k) خوشه است که در اینجا برای گروه بندی نودهای حسگر بی سیم به کار رفته است. در ابتدا، مختصات نودهای حسگر به صورت تصادفی یا طبق یک الگوی خاص در فضای دوبعدی شبکه (با ابعاد ۸۰×۸۰ متر) قرار می گیرند. سپس الگوریتم k-means اجرا می شود. در این فرآیند، ابتدا مراکز اولیه خوشه ها به صورت تصادفی تعیین می گردند و سپس به صورت تکراری نودها به نزدیک ترین مرکز تخصیص داده شده و مراکز جدید محاسبه می شوند تا جایی که همگرایی حاصل شود.

استفاده از k-means باعث خوشه بندی تطبیقی و واقع گرایانه تر در مقایسه با روش های دستی می شود، چرا که تقسیم بندی نودها به طور پویا و بر اساس موقعیت مکانی واقعی آن ها صورت می گیرد.

پس از تشکیل خوشه ها، برای هر خوشه، سرخوشه (Cluster Head) از میان نودهای عضو انتخاب می شود. معیار انتخاب سرخوشه، کمترین فاصله به مرکز خوشه k-means است. به بیان دیگر، نودی که نزدیک ترین مختصات به مرکز ثقل خوشه دارد، به عنوان سرخوشه تعیین می شود. برای اطمینان از توان عملیاتی بالای سرخوشه ها، به آن ها انرژی اولیه بیشتری (۳ ژول) نسبت به سایر نودها تخصیص داده می شود، در حالی که انرژی اولیه نودهای معمولی در بازه ۰,۵ تا ۱ ژول تعیین شده است.

وظایف اصلی سرخوشه ها شامل موارد زیر است:

- جمع آوری داده از نودهای عضو خوشه؛
- اعمال فشرده سازی داده ها برای کاهش حجم انتقالی؛
- ارسال مستقیم داده های فشرده به ایستگاه پایه (BS)، یا استفاده از سرخوشه های دیگر به عنوان رله در صورت زیاد بودن فاصله از (BS) مسیریابی چندمرحله ای.

جهت ارزیابی صحت عملکرد سرخوشه ها، مکانیزم شناسایی ناهنجاری (Anomaly Detection) نیز پیاده سازی شده است. هر سرخوشه در هر راند مقداری داده تصادفی تولید می کند که اگر خارج از بازه معین (مثلاً کمتر از ۱۰ یا بیشتر از ۵۰ واحد) باشد، به عنوان داده مشکوک تلقی شده و سرخوشه مربوطه به صورت موقت غیرفعال می شود. این رویکرد

تنظیمات اولیه شبیه سازی

در این شبیه سازی، شبکه شامل ۲۵ نود حسگر است که به ۵ خوشه تقسیم شده اند. هر خوشه دارای ۵ نود است که به صورت شعاعی و در اطراف مرکز خوشه (centroid) قرار گرفته اند. مختصات مراکز خوشه ها به صورت ثابت و پیش تعریف شده در نظر گرفته شده اند. ایستگاه پایه در مرکز میدان با مختصات (۴۰، ۴۰) قرار دارد. هر نود دارای انرژی اولیه متغیر بین ۰,۵ تا ۱ ژول است که به صورت تصادفی تخصیص داده شده است، به جز سرخوشه ها که انرژی بیشتری (۳ ژول) دارند تا توانایی پردازش و ارسال داده های خوشه را داشته باشند. پارامترهای مورد استفاده در این پروتکل در جدول ۳ نشان داده شده است.


جدول ۴: پارامترهای مورد استفاده در پروتکل

پارامتر	مقدار
تعداد سنسورها	۲۵ عدد
محیط شبکه	۸۰*۸۰ متر
انرژی اولیه سرخوشه ها	۳ ژول
انرژی اولیه سنسورها	۰,۵ تا ۱ ژول
جایگاه ایستگاه پایه	۴۰*۴۰ متر

مراحل شبیه سازی


در هر راند، مراحل زیر اجرا شدند:

۱. تشخیص ناهنجاری: سرخوشه ها داده های حسگرهای عضو خود را جمع آوری کرده و مقادیر غیرعادی بر اساس آستانه مشخص علامت گذاری شدند. سرخوشه هایی که داده نامعمول دریافت کردند، به طور موقت غیرفعال شدند. این ماژول نشان دهنده قابلیت TinyML در تحلیل اولیه داده ها و افزایش کیفیت آن ها است.
۲. انتقال داده و مصرف انرژی: انرژی مصرفی نودها و سرخوشه ها با در نظر گرفتن فشرده سازی هوشمند داده، مصرف اضافی ناشی از پردازش (ML) و مدل انرژی محاسبه شد. این مرحله شامل انتقال داده از نودها به سرخوشه و از سرخوشه به (BS) یا مسیر رله بود.



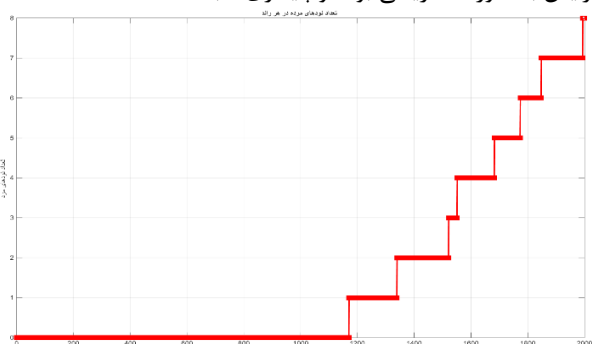
شکل ۴: انرژی باقی مانده در آخرین راند

نمودار تغییرات انرژی در طول راندها (شکل ۴) روند تدریجی کاهش انرژی در شبکه را نمایش می‌دهد. این نمودار نشان می‌دهد که انرژی نودها به تدریج کاهش می‌یابد و برخی نودها زودتر از بقیه به پایان عمر خود می‌رسند. این روند طبیعی برای شبکه‌های حسگر بی سیم است و اهمیت طراحی الگوریتم‌های صرفه‌جویانه در مصرف انرژی را نشان می‌دهد.



شکل ۵: نمودار خطی انرژی باقی مانده سنسورها

شکل ۵ تعداد نودهای مرده در هر راند را نمایش می‌دهد. مشاهده می‌شود که تعداد نودهای مرده با افزایش راندها افزایش می‌یابد، اما به دلیل مکانیزم‌های انتخاب سرخوشه و مسیریابی چندمرحله‌ای، این افزایش به صورت تدریجی بوده و پایداری شبکه حفظ شده است.



شکل ۶: تعداد نودهای مرده

نتایج شبیه‌سازی

نتایج شبیه‌سازی نشان می‌دهد که معماری پیشنهادی با ترکیب ماژول‌های تشخیص ناهنجاری، پیش‌بینی خطا، فشرده‌سازی داده و

به جلوگیری از ارسال اطلاعات نادرست و افزایش پایداری داده‌های نهایی کمک می‌نماید. به طور کلی، استفاده از الگوریتم k-means فرآیند خوشه‌بندی، موجب توزیع متعادل‌تر نودها در خوشه‌ها، کاهش مجموع فاصله ارتباطی بین نودها و سرخوشه‌ها، و افزایش بازدهی مصرف انرژی در سطح شبکه می‌شود. این الگوریتم خصوصاً در محیط‌هایی با توزیع نودهای نامتوازن عملکرد مؤثری از خود نشان می‌دهد.

مدل مصرف انرژی

در شبیه‌سازی، مدل انرژی شامل موارد زیر است:

- انرژی مصرفی برای ارسال داده‌ها شامل انرژی الکترونیکی و انرژی آمپلیفایر است که متناسب با اندازه بسته داده و فاصله ارسال محاسبه می‌شود.
- انرژی مصرفی برای دریافت داده‌ها به صورت انرژی الکترونیکی محاسبه شده است.
- مصرف انرژی برای فشرده‌سازی داده‌ها با توجه به نسبت فشرده‌سازی و انرژی مصرفی به ازای هر بیت تعریف شده است.
- علاوه بر این، هزینه انرژی مربوط به یادگیری ماشین (ML) نیز برای پردازش داده‌ها در سرخوشه‌ها لحاظ شده است.

پروسه انتقال داده و مدیریت انرژی

در هر راند از شبیه‌سازی، اعضای هر خوشه داده‌های خود را به سرخوشه ارسال می‌کنند که انرژی مصرفی این انتقال برای هر نود به روز می‌شود. سرخوشه‌ها داده‌ها را فشرده کرده و سپس بسته به فاصله خود تا استگاه پایه تصمیم می‌گیرند که داده‌ها را مستقیم ارسال کنند یا از طریق سرخوشه‌های دیگر به صورت چندمرحله‌ای انتقال دهند. این روش باعث کاهش مصرف انرژی در سرخوشه‌های دور از استگاه پایه می‌شود. همچنین مصرف انرژی مربوط به انتقال چندمرحله‌ای و پردازش داده در سرخوشه‌ها محاسبه و کسر می‌شود.

نتایج و تحلیل انرژی

شکل ۳ نمودار انرژی باقی‌مانده نودها را پس از آخرین راند نشان می‌دهد. همانطور که مشاهده می‌شود، سرخوشه‌ها به دلیل مصرف بالاتر انرژی برای ارسال و پردازش داده، انرژی کمتری نسبت به نودهای عادی دارند. با این وجود، مدیریت انتقال چندمرحله‌ای به حفظ انرژی برخی سرخوشه‌ها کمک می‌کند.

طول عمر شبکه در مقایسه با شبکه‌های بدون مدیریت هوشمند است.

۳. تعداد نودهای مرده: تعداد نودهای مرده با گذر زمان به آرامی افزایش می‌یابد، که نشان‌دهنده پایداری بالای شبکه است.
۴. کارایی TinyML در WSN: ترکیب ماژول‌ها امکان تحلیل و پیش‌بینی هوشمند داده‌ها، فشرده‌سازی مؤثر و مسیریابی بهینه را فراهم می‌کند و نشان می‌دهد که گره‌های کم‌منبع می‌توانند با حداقل مصرف انرژی، قابلیت‌های هوشمند داشته باشند.

جدول ۵: جدول مقایسه‌ای روش پیشنهادی با سایر روش‌ها

معیار ارزیابی	روش پیشنهادی (tiny ml)	روش‌های سنتی مانند (LEACH/HEED)
مصرف انرژی	کاهش چشمگیر به دلیل پردازش محلی	بالا به دلیل ارسال مداوم داده‌ها
دقت تشخیص ناهنجاری	بالا، به دلیل پردازش محلی و یادگیری	پایین، وابسته به ایستگاه پایه
طول عمر شبکه	افزایش یافته (تا چند برابر)	کوتاه‌تر
واکنش به رخدادها	سریع، تصمیم‌گیری در گره	کند به دلیل تأخیر در انتقال
میزان داده ارسالی به سرور	بسیار کمتر (فقط داده مهم)	زیاد

داده‌ها، و مسیریابی چندمرحله‌ای باعث کاهش بار ارتباطی و توزیع متوازن تر مصرف انرژی گردید. در این پروتکل، TinyML برای شناسایی ناهنجاری در داده‌های جمع‌آوری شده به کار رفت و باعث شد که تنها داده‌های معتبر به ایستگاه پایه ارسال شوند. این امر علاوه بر افزایش کیفیت داده‌ها، موجب صرفه‌جویی بیشتر در مصرف انرژی شد، زیرا داده‌های غیرضروری و مشکوک حذف گردیدند.

تحلیل نتایج شبیه‌سازی، از جمله نمودارهای انرژی باقی‌مانده و نرخ ازکارافتادگی نوده‌ها، نشان داد که ترکیب خوشه‌بندی k-means، فشرده‌سازی داده، مسیریابی چندمرحله‌ای، و پردازش محلی مبتنی بر TinyML می‌تواند طول عمر شبکه را به شکل قابل توجهی افزایش دهد و مصرف انرژی را به صورت تدریجی و متعادل کاهش دهد. به طور کلی، یافته‌های این تحقیق نشان می‌دهد که استقرار TinyML در سطح گره‌های حسگر، نه تنها امکان اجرای پردازش محلی و تصمیم‌گیری هوشمند را فراهم می‌کند، بلکه وابستگی به ایستگاه پایه را کاهش داده و تاب‌آوری شبکه را در برابر خطاها و اختلالات افزایش می‌دهد. این ویژگی‌ها می‌توانند زمینه‌ساز توسعه کاربردهای گسترده‌تر (WSN) در حوزه‌هایی نظیر اینترنت اشیا، کشاورزی هوشمند، پایش محیطی و سیستم‌های حیاتی شوند. برای آینده، پیشنهاد می‌شود پژوهش‌های تکمیلی به سمت استفاده از الگوریتم‌های تکاملی برای انتخاب پویا سرخوشه‌ها، ترکیب TinyML با یادگیری فدرال، و طراحی سازوکارهای امنیتی سبک حرکت کنند تا علاوه بر بهبود کارایی انرژی و طول عمر شبکه، قابلیت اطمینان و امنیت در مقیاس‌های بزرگ نیز تضمین گردد.

مسیریابی تطبیقی، توانسته عملکرد شبکه را در جنبه‌های مختلف بهبود دهد:

۱. توزیع انرژی نودها: نمودار انرژی نشان می‌دهد که سرخوشه‌ها با مصرف هوشمند انرژی و استفاده از فشرده‌سازی داده، قادر به فعالیت طولانی‌تر نسبت به نودهای عادی هستند.
۲. تغییرات انرژی در طول زمان: نمودار انرژی در طول ۲۰۰۰ راند کاهش تدریجی انرژی را نشان می‌دهد، که بیانگر افزایش

این نتایج نشان می‌دهند که معماری یکپارچه TinyML قادر است همزمان کیفیت داده، طول عمر شبکه و پایداری و اتکا پذیری آن را بهبود دهد و امکان استفاده از یادگیری ماشین سبک را در شبکه‌های حسگر با منابع محدود فراهم می‌کند.

۶- نتیجه گیری

در این پژوهش، رویکردی نوین مبتنی بر یادگیری ماشین کوچک (TinyML) برای افزایش اتکا پذیری و بهبود مدیریت انرژی در شبکه‌های حسگر بی‌سیم ارائه شد. معماری پیشنهادی با ادغام ماژول‌های تشخیص ناهنجاری، پیش‌بینی خرابی، فشرده‌سازی هوشمند داده و مسیریابی تطبیقی توانست به شکل مؤثری چالش‌های ناشی از محدودیت منابع پردازشی و انرژی را کاهش دهد. نتایج شبیه‌سازی نشان داد که استفاده از این چارچوب، علاوه بر افزایش طول عمر شبکه، موجب ارتقای کیفیت داده، کاهش بار ارتباطی، و حفظ پایداری شبکه در شرایط نامطمئن می‌شود. یکی از نوآوری‌های اصلی این مطالعه، به‌کارگیری TinyML (یادگیری ماشین فوق‌سبک) در سرخوشه‌ها برای پردازش و تحلیل محلی داده‌ها بود. TinyML با استفاده از مدل‌های بسیار کم‌حجم و بهینه‌شده، امکان اجرای الگوریتم‌های یادگیری ماشین را بر روی سخت‌افزارهای با منابع محدود فراهم می‌کند. یک پروتکل خوشه‌بندی و مدیریت انرژی برای شبکه‌های حسگر بی‌سیم با هدف افزایش طول عمر شبکه و بهبود کارایی انتقال داده ارائه و شبیه‌سازی شد. با استفاده از الگوریتم خوشه‌بندی k-means، تقسیم‌بندی بهینه‌تری از نودها به خوشه‌ها ایجاد کرده و با انتخاب سرخوشه بر اساس کمترین فاصله به مرکز خوشه، ارتباطات درون‌خوشه‌ای را بهینه نموده است. همچنین، تخصیص انرژی اولیه بیشتر به سرخوشه‌ها، بهره‌گیری از فشرده‌سازی

- 15 Jusuf Elfarahati TPEKAFESAA. Review of Wireless Sensor Network security. Defense and Security Studies. 2025.
- 16 Ghadeer Al Sukkar SAS. Enhancing Security in Wireless Sensor Networks: A Machine Learning-based Dos Attack Detection. Engineering, Technology & Applied Science Research. 2025.
- 17 HUYNH A. D. NGUYEN QPH. Wireless Sensor Network Dependable Monitoring for Urban Air Quality. IEEE. 2022.
- 18 ArashHeidari ZMN. Assessmentofreliability andavailability of wireless sensornetworksinindustrialapplications byconsidering permanentfaults. WILEY. 2024.
- 19 Athanasios Trigkas DP,P. Edge Intelligence in Urban Landscapes: Reviewing TinyML Applications for Connected and Sustainable Smart Cities. MDPI. 2025.
- 20 Spyridon Giazitzisa AAINBAMPDMRSBFREO. TinyML models for SoH estimation of lithium-ion batteries based on Electrochemical Impedance Spectroscopy. ScienceDirect. 2025.
- 21 Iyad Katib EASASMR. Safeguarding IoT consumer devices: Deep learning with TinyML driven real-time anomaly detection for predictive maintenance. ScienceDirect. 2025.
- 22 Dennis Agyemanh Nana Gookyi EAEAjOA. TinyML for smart agriculture: Comparative analysis of TinyML platforms and practical deployment for maize leaf disease identification. ScienceDirect. 2024.
- 23 Sergio Trillesa bSSHDI. AnomalydetectionbasedonArtificialIntelligence of Things: A Systematic Literature Mapping. ScienceDirect. 2024.
- 24 Franklin Oliveiraa DGCF AIS. Internet of Intelligent Things: A convergence of embeddedsystems,edgecomputingandmachinelearning. ScienceDirect. 2024.
- 25 Nikolaos Schizas AKCKSS. TinyML for Ultra-Low Power AI and Large Scale IoT Deployments: A Systematic Review. MDPI. 2022.
1. SONAM LATA SSU. Secure and Reliable WSN for Internet of Things:Challenges and Enabling Technologies. IEEE. 2021.
2. ABADADE Y, TEMOUDEN A, BAMOUMEN H, BENAMAR N, CHTOUKI Y, SENHAJI HAFID A. A Comprehensive Survey on TinyML. ieee. 2023.
3. KEYAN CAO YL,MQS. An Overview on Edge Computing Research. IEEE. 2020.
4. Montaser N.A. Ramadan MAHASYKMA. Federated learning and TinyML on IoT edge devices: Challenges, advances, and future directions. ScienceDirect. 2025.
5. Kalpana Sharma MKG. Wireless Sensor Networks: An Overview on its Security and threats. IJCA Special Issue on "Mobile Ad-hoc Networks". 2010.
6. Elham Alotaibi RBSMA. Assessment of cybersecurity threats and defense mechanisms in wireless. Journal of Cyber Security and Risk Auditing. 2025.
7. MF, AG, EM, FP, RP, SR. Federated learning for IoT devices: Enhancing TinyML with on-board. ELSEVIER. 2024.
8. F. García-Hernández C, H. Ibarguengoytia-González P, García-Hernández J, A. Pérez-Díaz. Wireless Sensor Networks and Applications: a Survey. IJCSNS International Journal of Computer Science and Network Security. 2007.
9. Salam Hamdan MA,A. Edge-Computing Architectures for Internet of Things. MDPI. 2020.
- 10 WEI YU FXHWGH. A Survey on the Edge Computing for the internet of things. IEEE. 2018.
- 11 YONGLI ZHAO WWYLCCMMJZ. Edge Computing and Networking: A Survey on infrastructures and applications. IEEE. 2019.
- 12 ZHIZHOU X,ZLJZ. Edge Intelligence: Paving the lasr mile of artificial intelligence with edge computing. IEEE. 2019.
- 13 yuan ai mpkz. Edge computing technologies for internet of Things: a primer. ELSEVIER. 2018.
- 14 Moslehi MM. Exploring coverageandsecuritychallenges in wireless sensor networks: A survey. ELSEVIER. 2025.

تعارض منافع

هیچ گونه تعارض منافع توسط نویسندگان بیان نشده است.