



Semnan University

Journal of Modeling in Engineering

Journal homepage: <https://modelling.semnan.ac.ir/>

ISSN: 2783-2538



Research Article

A Model Based Neural Network SOM and Grey Wolf Algorithm for Reducing Latency and Energy Consumption in IoT

Murtadha Jaber Obaid Albo Jasim^a, Mahdi Mazinani^{b,*}, Abbas Koochari^a^a Department of Computer Engineering, Science and Research Branch, Islamic Azad University, Tehran, Iran^b Department of Electrical and Electronic Engineering, ShQ.C., Islamic Azad University, Shahr-e Qods, Iran

PAPER INFO

Paper history:

Received: 2023-12-31

Revised: 2024-05-31

Accepted: 2024-12-30

Keywords:

Wireless sensor network;
Internet of things;
Grey wolf optimize
algorithm;
Self-Organizing map
neural network;
Energy consumption;
Delay.

ABSTRACT

In the optimization of the Internet of Things (IoT) environment, devising solutions for network challenges, including scalability, routing, reliability, security, energy efficiency, network lifetime, density, heterogeneity, and quality of service, is essential. In this context, the utilization of cutting-edge approaches for monitoring and managing energy consumption and end-to-end delay (E2ED) holds paramount significance. This research addresses these concerns by clustering wireless sensor network nodes as a subset of the Internet of Things, employing a combination of the Self-Organizing Map (SOM) neural network pattern and the Grey Wolf Optimizer (GWO) algorithm for evaluation. In wireless sensor networks, the network layer manages routing challenges, and optimizing the efficiency of power consumption is crucial due to the substantial energy requirements of radio transmission. Consequently, conserving energy becomes a critical consideration in wireless sensor networks. Recent studies have concentrated on developing energy-efficient routing algorithms that reduce energy consumption during communications, thereby extending the network's lifespan. This research introduces and analyzes the SOM-GWO method and an energy-efficient routing algorithm. Simulation is conducted using Python, and a comparative assessment is made against protocols like LEACH, HEED, SOM-LEACH, and EESOM. Results indicate respective increases of 20%, 14.8%, 12.5%, and 3.8% in network lifetime. Furthermore, the proposed method exhibits a reduction of 37.5%, 33.3%, 16.6%, and 6.25% in average energy consumption compared to conventional algorithms. Based on empirical data from simulations, the proposed algorithm excels in terms of network lifetime, packet delivery ratio, operational power, and buffer occupancy.

DOI: <https://doi.org/10.22075/jme.2024.32849.2600>

© 2025 Published by Semnan University Press.

This is an open access article under the CC-BY 4.0 license. (<https://creativecommons.org/licenses/by/4.0/>)

* Corresponding author.

E-mail address: mahdi.mazinani@iaui.ac.ir

How to cite this article:

M. Jaber Obaid Albo Jasim, M. Mazinani and A. Koochari, "A Model Based Neural Network SOM and Grey Wolf Algorithm for Reducing Latency and Energy Consumption in IoT," Journal of Modeling in Engineering, 23 82 (2025): 65-83, doi: 10.22075/jme.2024.32849.2600

ارائه یک مدل مبتنی بر شبکه‌های عصبی SOM و الگوریتم گرگ خاکستری برای کاهش تاخیر و مصرف انرژی در اینترنت اشیا

مرتضی جابر عبید البو جاسم^۱، مهدی مزینانی^{۲*}، عباس کوچاری^۱

چکیده	اطلاعات مقاله
در بهینه‌سازی محیط اینترنت اشیا (IoT)، راهکارهایی برای مشکلات شبکه از جمله مقیاس‌پذیری، مسیریابی، امنیت، مصرف انرژی، طول عمر شبکه، تراکم، ناهمگونی و کیفیت خدمات ضروری است. در این راستا، استفاده از روش‌های پیشرو در مدیریت مصرف انرژی برای ارزیابی آن، حائز اهمیت است. پژوهش کنونی با خوشه‌بندی گره‌های شبکه حسگر بی‌سیم (WSN)، با ترکیب الگوی شبکه عصبی SOM و الگوریتم بهینه‌ساز گرگ خاکستری (GWO)، این مقوله را ارزیابی کرده است. در شبکه‌های حسگر، لایه شبکه مشکلات مسیریابی را مدیریت می‌کند. از آنجایی که انتقال رادیویی به مقدار قابل توجهی انرژی نیاز دارد، بررسی کارایی توان و بهینه‌سازی آن ضروری است. در نتیجه، حفظ انرژی یک نگرانی حیاتی در شبکه‌های حسگر بی‌سیم است. تحقیقات اخیر بر روی توسعه الگوریتم‌های مسیریابی متمرکز شده است که انرژی کمتری را در طول ارتباطات مصرف می‌کنند و در نتیجه عمر شبکه را طولانی‌تر می‌کنند. شبکه‌های حسگر بی‌سیم با گره‌های بازیابی انرژی از گره‌هایی استفاده می‌کنند که می‌توانند انرژی را از محیط خود استخراج کنند. روش SOM-GWO و الگوریتم مسیریابی انرژی آگاه در این پژوهش پیشنهاد و تحلیل شده است. مقایسه پروتکل‌های HEED، LEACH، SOM-LEACH، EESOM، با پروتکل پیشنهادی SOM-GWO مشخص نمود که طول عمر شبکه به ترتیب ۲۰، ۱۴.۸، ۱۲.۵ و ۳.۸ درصد افزایش یافته است. علاوه بر این، روش پیشنهادی در مقایسه با سایر الگوریتم‌ها دارای کاهش ۳۷.۵، ۳۳.۳، ۱۶.۶ و ۶.۲۵ درصدی در میانگین مصرف انرژی است. با توجه به داده‌های به‌دست‌آمده از شبیه‌سازی، الگوریتم پیشنهادی در طول عمر شبکه، نسبت تحویل بسته، توان عملیاتی و اشغال بافر عملکرد بهتری دارد.	دریافت مقاله: ۱۴۰۲/۱۰/۱۰ بازنگری مقاله: ۱۴۰۳/۰۳/۱۱ پذیرش مقاله: ۱۴۰۳/۱۰/۱۰
	واژگان کلیدی: حسگر بی‌سیم، اینترنت اشیا، الگوریتم گرگ خاکستری، شبکه عصبی SOM، مصرف انرژی، تاخیر.

DOI: <https://doi.org/10.22075/jme.2024.32849.2600>

© 2025 Published by Semnan University Press.

This is an open access article under the CC-BY 4.0 license. (<https://creativecommons.org/licenses/by/4.0/>)

۱- مقدمه

این فناوری به هر چیز یک شناسه منحصر به فرد و همچنین یک آدرس IP تعلق می‌گیرد که بتواند داده‌ها را برای پایگاه داده مشخص شده ارسال کند. IoT، می‌تواند میلیاردها دستگاه را به‌منظور جمع‌آوری و تبادل اطلاعات به‌صورت

در دنیای امروزی، داده و اطلاعات حرف اول را می‌زنند؛ اینترنت اشیا (IoT)^۲ نیز بر پایه داده شکل گرفته و آن را به تمامی اشیای پیرامون محیط زندگی بسط داده است. در

* پست الکترونیک نویسنده مسئول: mahdi.mazinanani@iaui.ac.ir

۱. گروه مهندسی کامپیوتر، واحد علوم و تحقیقات، دانشگاه آزاد اسلامی، تهران، ایران

۲. گروه مهندسی برق و الکترونیک، واحد شهرقدس، دانشگاه آزاد اسلامی، شهرقدس، ایران

استناد به این مقاله:

مرتضی جابر عبید البو جاسم، مهدی مزینانی و عباس کوچاری، "ارائه یک مدل مبتنی بر شبکه‌های عصبی SOM و الگوریتم گرگ خاکستری برای کاهش تاخیر و مصرف انرژی در اینترنت اشیا"، مدل سازی در مهندسی، ۸۲ (۱۴۰۴): ۶۵-۸۳، doi: 10.22075/jme.2024.32849.2600

² Internet of Things (IoT)

در واقع براساس دو پارامتر سطح انرژی و همسایگی، مجموعه‌ای در شبکه با انرژی متوازن تشکیل خواهند شد. به‌علاوه یک تابع هزینه جدید به‌منظور تصمیم‌گیری در انتخاب گره‌های ذخیره‌کننده اطلاعات، پیشنهاد شده است که سعی در ترکیب معیارهای مختلف موثر در انتخاب بر اساس میزان اهمیت آن‌ها دارد. کارایی برتر این پروتکل از لحاظ افزایش طول عمر مفید شبکه و حفظ بهتر پوشش شبکه‌ای در مقایسه با پروتکل‌های پیشین نیز تاثیر تابع هزینه پیشنهادی بر کارایی آن و نیز حفظ اطلاعات ذخیره شده با شبیه‌سازی به اثبات می‌رسد.

همچنین برای اثربخشی بهینه، الگوریتم گرگ خاکستری (GWO) [۴] براساس میزان سطح انرژی هر گره و با استفاده از تعیین فاصله با گره همسایه و میزان بار اعمال شده به هر گره، مسیریابی را با هدف کاهش تداخل سیگنال‌های ارسالی بهبود داده‌ایم. تلاش تحقیق حاضر این بوده است که با بهبود ایده سنتی مسیریابی بر حسب مکان، به‌منظور رسیدن به هدف اصلی شبکه‌های IoT یعنی افزایش طول عمر شبکه همزمان با حفظ پوشش شبکه‌ای، روشی یک پارچه برای مسیریابی مبتنی بر میزان انرژی ارائه گردد. در این روش وزن دهی، موقعیت مناسب گره بعدی، جهت توزیع مناسب انرژی در جهت مسیریابی درست در نظر گرفته شده است که در نهایت، موجب کاهش تداخل و افزایش طول عمر شبکه می‌شود. در واقع هرچه وزن یک یال بیشتر باشد، ارزش آن یال نیز بیشتر است.

۱-۲- انگیزه و مشارکت

شبکه عصبی مصنوعی، سیستمی بزرگ از اجرا پردازشی موازی یا توزیع شده به نام نورون یا سلول عصبی است که در یک توپولوژی گراف به هم متصل شده‌اند. نورون‌ها از طریق ارتباطات وزن‌داری به نام سیناپس به هم متصل می‌شوند. داده‌ها جدا از پردازش ذخیره نمی‌شوند، زیرا داده‌ها به‌طور ذاتی به هم متصل هستند. به عبارت دیگر، شبکه‌های عصبی مصنوعی، الگوریتم‌های ریاضی هستند که قادر به یادگیری نگاشت‌های پیچیده بین ورودی (ها) و خروجی (ها) از طریق آموزش تحت نظارت^۵ بوده یا قادر به رده‌بندی اطلاعات ورودی به روشی بدون نظارت^۶ می‌باشند. قوانین آموزش این شبکه‌ها الهام گرفته از علم زیست‌شناسی بوده و نحوه یادگیری شبکه را تعیین می‌کنند. انواع مختلفی از

بی‌درنگ برای ارائه خدمات هوشمند، به یکدیگر متصل کند. اینترنت اشیا به سرعت رشد کرده است و بسیاری از خدمات، نرم‌افزارها، دستگاه‌های الکترونیکی تعبیه‌شده در حسگرها و پروتکل‌های مرتبط که توسعه یافتند هنوز با نوسان کامل در حال پیشرفت هستند.

شبکه حسگر بی‌سیم (WSN)^۳ به‌عنوان پایه‌ای برای اکثر برنامه‌های کاربردی اینترنت اشیا عمل می‌کند. بنابراین تهدیدها و چالش‌های فنی کلی و خاص برای شبکه‌های حسگر مبتنی بر اینترنت اشیا وجود دارد که باید برای اطمینان از سازگاری و انتشار آن بر آنها غلبه کرد. بیشتر محدودیت‌های شبکه‌های حسگر بی‌سیم به دلیل ماهیت اشیا محدودیت منابع آن است. مهم‌ترین مسئله شبکه‌ها، انرژی محدود گره‌ها است. عمده مصرف انرژی گره‌ها مربوط به ارسال و دریافت داده‌ها توسط گره‌ها است. در برخی موارد وجود گره‌های خودخواه که در مصرف منابع شبکه رفتار خودخواهانه دارند، که باعث افزایش مصرف انرژی می‌شود. یکی از رویکردها برای حل این مشکل بهره‌گیری از معماری مسیریابی انرژی آگاه است [۱]. از این رو، معرفی روش‌های مسیریابی انرژی موثر، به‌عنوان مهم‌ترین عامل مدیریت مصرف انرژی در این شبکه‌ها محسوب می‌شود. در اغلب اوقات، برای نگهداری انرژی، گره‌های بیکار در حالت خواب باقی می‌مانند و به‌صورت دوره‌ای به حالت فعال در می‌آیند تا داده‌های حس شده را بدست آورند و آنها را ارسال کنند.

طراحی پروتکل‌های مسیریابی به دلیل برخی از محدودیت‌های شبکه از قبیل انرژی، پهنای باند، محدودیت واحد پردازش و ذخیره‌سازی دارای چالش‌هایی می‌باشد [۳،۲]. تاکنون پروتکل‌های مسیریابی بسیاری ارائه شده‌اند، با این حال، در مدیریت بهینه شبکه برای برآوردن نیازهای کیفیت خدمات (QoS)^۴ کارایی لازم را ندارند. در این تحقیق، از مفهوم شبکه‌های حسگر بی‌سیم در کنار اینترنت اشیا استفاده شده تا بتوان ذخیره‌سازی اطلاعات در گره‌های شبکه بر اساس سطح انرژی و مختصات گره‌ها انجام شود. این پروتکل با استفاده از تعداد مشخصی از گره‌های پرانرژی در شبکه و اعمال آنها به‌عنوان وزن نورون‌های نزدیک‌ترین گره‌های کم‌انرژی را جذب گره‌های پرانرژی می‌کند؛ به‌طوری‌که اطلاعات لزوماً در گره‌های مجاور ذخیره نشده و

^۵ Supervised learning

^۶ Unsupervised Learning

^۳ Wireless Sensor Network (WSN)

^۴ Quality of Service (QoS)

شبکه‌های عصبی وجود دارند که هر کدام بنا بر کاربرد خود از توانایی‌های مختلفی برخوردار می‌باشند. در اغلب شبکه‌های عصبی، آموزش شبکه بر اساس یادگیری مبتنی بر مثال^۷ انجام می‌شود. یعنی مجموعه‌ای از داده‌های ورودی - خروجی درست به شبکه داده می‌شود.

دسته مهم دیگری از شبکه‌های عصبی، شبکه‌های خودسازمانده^۸ (بدون نظارت) هستند که به‌طور خودکار به دسته‌بندی و رده‌بندی داده‌های ورودی می‌پردازند. یکی از دشوارترین مسایل در شبکه‌های عصبی مصنوعی، انتخاب مناسب‌ترین توپولوژی شبکه برای مساله است. انواع مختلفی از شبکه‌های عصبی وجود دارند که هر یک بنا بر کاربرد دارای توانایی‌های مختلفی هستند. توانایی شبکه‌های حسگر به ساختار، پویایی و روش‌های آموزشی آن بر می‌گردد. مهمترین کاربردهای شبکه‌های عصبی را به‌طور کلی می‌توان پیش‌بینی، رده‌بندی و شناسایی ذکر نمود.

اما سوال مهمی که در اینجا مطرح می‌شود این است که شبکه‌های عصبی چگونه می‌توانند به ذخیره انرژی (کاهش مصرف انرژی) در شبکه‌های حسگر بی‌سیم کمک کنند؟

در سکوها شبکه‌های حسگر بی‌سیم که از ماهیت فازی و غیرقابل پیش‌بینی برخوردار بوده و پارامترهای مختلفی در رفتار آن‌ها نقش دارند، شبکه‌های عصبی از طریق کاهش ابعاد داده می‌توانند منجر به کاهش ارتباطات و ذخیره انرژی گردند [۵]. به‌علاوه از آن‌جایی که شبکه‌های حسگر بی‌سیم ماهیت متمرکز دارند، یعنی اینکه داده‌های حاصل از همه گره‌های شبکه باید به یک ایستگاه مبنا ارسال شوند، قابلیت شبکه عصبی در پیش‌بینی اندازه‌گیری‌های گره‌های حسگر می‌تواند، ارتباطات غیرضروری را به شدت کاهش داده و باعث ذخیره انرژی شبکه گردد.

انگیزه مهم دیگر برای به‌کارگیری روش‌های مبتنی بر شبکه‌های عصبی در شبکه‌های حسگر بی‌سیم، وجود شباهت ذاتی بین این دو است. چنانچه [۶] اعتقاد دارند که شبکه‌های عصبی مصنوعی از معماری مشابه با شبکه‌های حسگر بی‌سیم برخوردارند؛ به‌طوری که نورون‌ها معادل گره‌های حسگر و ارتباطات وزن‌دار (سیناپس‌ها) معادل لینک‌های رادیویی می‌باشند. همچنین آن‌ها این‌طور نتیجه می‌گیرند که به‌کارگیری الگوی شبکه عصبی در محیط شبکه‌های حسگر می‌تواند منجر به درک بهتر و عمیق‌تر محیط گردد. با این دیدگاه، می‌توان کل شبکه حسگر را

به‌عنوان یک شبکه عصبی در نظر گرفت که در آن هر گره حسگر برای تصمیم‌گیری در مورد فعالیت خروجی خود از یک شبکه عصبی استفاده کند. بنابراین، پیاده‌سازی کارای شبکه‌های عصبی که از محاسبات ساده‌ای برخوردار باشد، می‌تواند جایگزین الگوریتم‌های سنتی پردازش سیگنال شده و پردازش داده‌ها در گره‌های حسگر را با مصرف منابع (انرژی و محاسباتی) کمتری امکان‌پذیر سازد.

نوآوری پژوهش حاضر به شرح زیر است:

- استفاده از شبکه عصبی SOM و الگوریتم بهینه‌ساز گرگ خاکستری (GWO)، علاوه بر کاهش مصرف انرژی و افزایش طول عمر شبکه، سبب بهبود پوشش‌دهی در شبکه و کاهش تاخیر در انتقال بسته‌ها گردیده است.
- پهنای باند اشیا با استفاده از الگوریتم مسیریابی انرژی آگاه SOM-GWO بهبود یافته است.

۱-۳- انگیزه و مشارکت

ادامه پژوهش به شرح زیر است. دانش پس‌زمینه در خصوصی شبکه عصبی SOM و الگوریتم GWO در بررسی پیشینه موجود در بخش دوم ارائه گردیده است. بخش سوم روش پیشنهادی و طرح مسئله مربوط به حوزه کاهش مصرف انرژی و تاخیر در IoT ارائه نموده است.

در بخش چهارم نتایج شبیه‌سازی برتری روش پیشنهادی را از منظر کاهش مصرف انرژی و تاخیر در IoT نشان داده‌اند. در نهایت، نتیجه‌گیری و پیشنهادهای تی در بخش پنجم بیان گردیده است.

۲- دانش پس‌زمینه و پیشینه پژوهش

در این بخش مفاهیم و دانش مقدماتی پژوهش حاضر و پیشینه‌ای در خصوص خوشه‌بندی IoT/WSN ارائه گردیده است.

۱-۲- شبکه عصبی SOM

شبکه عصبی کوهونن (SOM) یک شبکه عصبی بدون ناظر است که برای خوشه‌بندی و کاهش ابعاد استفاده می‌شود. این شبکه از یک شبکه از نورون‌ها تشکیل شده است، که هر نورون نمونه‌ای از یک خوشه را نمایندگی می‌کند. SOM برای سازماندهی داده‌های ورودی به‌صورت توپولوژیکی و حفظ روابط مکانی بین نقاط داده آموزش داده می‌شود [۷]. SOM لایه ورودی را با لایه رقابتی از نورون‌های پردازشی

^۸ Self Organizing

^۷ Learning by example

$\vec{A}$ انجام می‌شود. از آنجا که $\vec{A}$ برداری تصادفی در بازه $[-2a, 2a]$ است، با کاهش a ، بردار ضرایب $\vec{A}$ نیز کاهش می‌یابد. اگر $|\vec{A}|$ کوچک‌تر از ۱ باشد، گرگ آلفا به شکار (و بقیه گرگ‌ها) نزدیک می‌شود و اگر $|\vec{A}|$ بزرگ‌تر از گرگ از شکار (و بقیه گرگ‌ها) دور خواهد شد. تمام گرگ‌ها موقعیت خود را برحسب موقعیت گرگ‌های آلفا، بتا و دلتا بروزسانی کنند. مدل ریاضی رفتار محاصره در معادله‌های زیر ارائه شده است؛ که t تکرار فعلی، $\vec{A}$ و $\vec{C}$ بردارهای ضریب هستند، $\vec{X}_p$ بردار موقعیت طعمه است و $\vec{X}$ بردار موقعیت گرگ خاکستری را نشان می‌دهد.

$$\vec{D} = |\vec{C} \cdot \vec{X}_p(t) - \vec{X}(t)|, \vec{C} = 2 \cdot \vec{r}_2 \quad (1)$$

$$\vec{X}(t+1) = |\vec{X}_p(t) - \vec{A} \cdot \vec{D}|, \vec{A} = 2 \cdot a \vec{r}_1 \quad (2)$$

در روابط بالا متغیر a به‌طور خطی در طول تکرارها از ۲ به ۰ کاهش می‌یابد و $\vec{r}_1, \vec{r}_2$ بردارهای تصادفی در بازه $[0,1]$ هستند. سه راه‌حل بهینه اول ذخیره می‌شوند و عامل‌های دیگر موقعیت‌های خود را مطابق با موقعیت بهترین عوامل جستجو به‌صورت زیر به روز می‌کنند.

$$\vec{D}_\alpha = |\vec{C}_1 \cdot \vec{X}_\alpha - \vec{X}|, \vec{D}_\beta = |\vec{C}_2 \cdot \vec{X}_\beta - \vec{X}|, \vec{D}_\delta = |\vec{C}_3 \cdot \vec{X}_\delta - \vec{X}| \quad (5)$$

$$\vec{X}_1 = \vec{X}_\alpha - \vec{A}_1 \cdot (\vec{D}_\alpha), \vec{X}_2 = \vec{X}_\beta - \vec{A}_2 \cdot (\vec{D}_\beta), \vec{X}_3 = \vec{X}_\delta - \vec{A}_3 \cdot (\vec{D}_\delta) \quad (6)$$


$$\vec{X}(t+1) = \frac{\vec{X}_1 + \vec{X}_2 + \vec{X}_3}{3} \quad (7)$$

در هنگام جستجو گرگ‌ها، برعکس مرحله محاصره، از یکدیگر دور می‌شوند تا شکار را ردیابی کنند. این رفتار تعادلی بین همگرایی و واگرایی الگوریتم برقرار می‌کند. بردار $\vec{C}$ به شکار وزن داده و آن را برای گرگ‌ها غیرقابل دستیابی‌تر می‌کند. این بردار برخلاف a به‌صورت خطی از ۲ تا ۰ کاهش نمی‌یابد. درنهایت برازندگی کلیه جواب‌ها محاسبه شده و سه جواب برتر به‌عنوان آلفا، بتا و دلتا تا پایان الگوریتم انتخاب می‌شوند.

۲-۳- سوابق پژوهش

در اغلب کاربردها، گره‌های حسگر از نظر منبع انرژی با محدودیت مواجه هستند. بنابراین نیاز به روش‌های ابتکاری برای برطرف نمودن اتلاف انرژی که موجب کوتاه شدن طول عمر شبکه‌های حسگر می‌گردد، کاملاً احساس می‌گردد. این

ترکیب می‌کند، که به‌طور معمول به‌صورت یک شبکه دوبعدی سازمان یافته‌اند. ساختار شبکه SOM همانطور که در شکل ۱ نشان داده شده است، شامل یک آرایه با $M = m \times n$ نورون پردازشی است. n مؤلفه بردار ورودی x یعنی $(x_1, x_2, \dots, x_n)$ به هر نورون در آرایه متصل شده‌اند. بنابراین، برای هر نورون j یک بردار وزن w_{ij} جهت اتصال مؤلفه i ام بردار ورودی به نورون j تعریف می‌شود. در نتیجه، برای هر نورون j یک بردار وزن همگن n بعدي w_j با هر نورون مرتبط است.



شکل ۱- نمایش ساده‌ای از SOM [۷]

فرآیند تطابق وزن و ایده همسایگی نورون‌ها دو مسئله مهم در الگوریتم یادگیری شبکه SOM هستند. ابتدا مقادیر تصادفی کوچکی برای وزن‌ها تنظیم می‌شوند و یک الگو به گره‌های ورودی شبکه ارائه می‌شود. در مرحله تطابق شباهت، فاصله اقلیدسی بین ورودی‌ها و وزن‌های مرتبط با نورون‌های خروجی محاسبه می‌شود. سپس نورون خروجی j که کمترین فاصله را در میان M نورون خروجی دارد، به‌عنوان نورون برنده اعلام می‌شود. در مرحله دوم، وزن‌ها گره‌های ورودی براساس نورون برنده تغییر می‌یابد. به عبارتی، نورون‌های نزدیک به نورون برنده شناسایی می‌شود و وزن‌های همگرا به این نورون‌ها تغییر می‌کنند.

۲-۲- الگوریتم بهینه‌سازی گرگ خاکستری

در بهینه‌سازی گرگ خاکستری (GWO) [۴]، مناسب‌ترین راه‌حل را به‌عنوان گرگ آلفا (α) در نظر گرفته می‌شود، و راه‌حل‌های دوم و سوم مناسب به ترتیب گرگ‌های بتا (β) و دلتا (δ) نامگذاری می‌شوند. بقیه راه‌حل‌ها امگا (ω) در نظر گرفته می‌شوند. در GWO، شکار توسط آلفا، بتا و دلتا هدایت می‌شود. راه‌حل‌های امگا از این سه گرگ پیروی می‌کند.

مدل کردن فرآیند محاصره طعمه با استفاده از کاهش بردار

محدودیت‌ها به همراه زیاد بودن تعداد گره‌های حسگر باعث چالش‌های بسیاری در طراحی و مدیریت شبکه‌های حسگر بی‌سیم و لزوم آگاهی از انرژی در همه لایه‌های پشته پروتکل شبکه‌ای شده است. برای مثال، در لایه شبکه، به شدت به یافتن روش‌هایی نیاز داریم که با بهره‌وری در مصرف انرژی، کشف مسیر انجام داده و داده‌ها را از گره‌های حسگر به ایستگاه مبنا انتقال دهند. این بخش به تعدادی از پژوهش‌های اخیر که در حوزه کاهش مصرف انرژی در اینترنت اشیا فعالیت داشته‌اند پرداخته است.

در [۸] از شبکه‌های عصبی برای مدیریت پویای توان (بیشینه کردن طول عمر گره‌های حسگر بعد از استقرار) و زمان‌بندی چرخه وظایف گره‌های حسگر (تعیین اینکه کدام گره در چه زمانی خواب یا بیدار باشد) استفاده شده است. در این روش، زمان رویداد بعدی یک سری غیر ثابت است که با استفاده از شبکه‌های عصبی موجک^۹ تا حد امکان به‌طور دقیق پیش‌بینی می‌شود. شبکه عصبی مذکور در واقع یک شبکه سه لایه است که در لایه مخفی از تبدیل موجک مورلت^{۱۰} استفاده می‌کند.

در [۹] هر گره حسگر از یک شبکه عصبی هاپفیلد^{۱۱} برای ذخیره وابستگی‌های میانگین میان اجزا الگو به کار گرفته شده است. حافظه انجمنی^{۱۲} شبکه‌عصبی هاپفیلد می‌تواند الگوهای گم‌شده یا خراب شده را از نو ایجاد کند. از الگوی اصلاح شده یا تکمیل شده می‌توان برای ساخت بسته‌های داده‌ای استفاده نمود.

در [۶] از SOM در یک معماری شبکه‌ای سلسله‌مراتبی (مبتنی بر خوشه) استفاده نمودند که در آن گره‌ها در چندین خوشه به همراه سرخوشه‌ها یا مراکز ترکیب داده، سازماندهی شده‌اند. این شبکه عصبی خودسازمانده، در عین حال که میزان داده‌هایی که باید انتقال داده شوند را کاهش می‌دهد، رده‌بندی الگوهای مشابه را نیز انجام می‌دهد.

در [۱۰]، از الگوریتم بهینه‌سازی نهنگ (WOA) برای حل مسئله تخصیص منابع در اینترنت اشیا با هدف بهینه‌سازی مصرف انرژی و کاهش هزینه کل ارتباطات بین منابع و دروازه‌ها استفاده نمودند این رویکرد از نظر هزینه ارتباطی کل عملکرد بهتری را نسبت به روش‌های دیگر داشته است. کومار و همکاران [۱۱]، به ارائه یک مطالعه تطبیقی برنامه‌ریزی وظایف و کاهش مصرف انرژی با استفاده از

رویکرد بهینه‌سازی کلونی مورچگان (ACO) و خوشه‌بندی K-Means در IoT با هدف جستجوی کوتاه‌ترین مسیر از مبدا به مقصد پرداختند. فرض شده که منابع متنوع و فعالی در شبکه اینترنت اشیا برای این دو الگوریتم وجود دارد. این مدل از نظر زمان پاسخ، تاخیر نقطه به نقطه، توان عملیاتی و سربار بیت‌های کنترلی دارای نتایج کارا و بهینه‌ای نسبت به رویکردهای مقایسه شده داشته است.

کومار و همکاران [۱۲] در مقاله خود به بهینه‌سازی مصرف انرژی برای برقراری ارتباط سبز در محیط‌های IoT/WSN پرداختند. این مقاله یک چارچوب ارتباطی سبز الهام گرفته از کوانتوم برای تعادل انرژی در سیستم‌های اینترنت اشیا فعال شده با حسگر (Q-EBIoT) را پیشنهاد می‌کند. بر اساس رویکرد پیشنهادی، در ابتدا، یک مدل بهینه‌سازی انرژی برای محیط‌های اینترنت اشیا فعال شده با حسگر ارائه شده است که در آن مصرف انرژی به‌عنوان تابع هدف مسیرهای انرژی‌گرا بدست می‌آید. دوم، یک راه‌حل محوری محاسبات کوانتومی برای مسئله بهینه‌سازی با تمرکز بر نمایش، اندازه‌گیری و زاویه چرخش محوری انرژی توسعه یافته است. روش پیشنهادی برای ارزیابی عملکرد مقایسه‌ای با تکنیک‌های پیشرفته اجرا شده است. ارزیابی صورت گرفته در مقاله، مزیت چارچوب پیشنهادی را از نظر معیارهای مختلف مربوط به انرژی برای محیط اینترنت اشیا فعال شده با حسگر نشان می‌دهد.

خسروی و همکاران [۱۳] بر روش‌های مسیریابی انرژی آگاه مبتنی بر ناحیه‌بندی فیزیکی در شبکه‌های حسگر صوتی متراکم و اینترنت اشیا زیرآبی پرداختند. در این مقاله مساله طول عمر گره‌ها و پایداری شبکه برای انتقال اطلاعات مهم‌ترین پارامتر در طراحی شبکه‌های مخابراتی صوتی در زیرآب است زیرا معمولاً تعویض باتری به دلیل شرایط پیچیده استقرار حسگرها در زیرآب، به راحتی امکان پذیر نیست. بنابراین بهبود مصرف انرژی شبکه بسیار مهم است تا جایی که باتری‌ها نهایت طول عمر را داشته باشند. در این بین، از طریق بهینه‌سازی فرایند مسیریابی می‌توان به شکل موثرتری به کاهش مصرف انرژی کمک کرد.

سرلک و محمدی نژاد [۱۴] در مقاله خود به بررسی تاثیر مسیریابی جهت کاهش مصرف انرژی در اینترنت اشیا پرداختند. در این مقاله از روش مسیریابی توسط

¹¹ Hopfield¹² Associative Memory⁹ Wavelet Neural Network¹⁰ Morlet Wavelet transform

پیچیده و پویای IoT را با نگاشت داده‌های ورودی با ابعاد بالا به یک شبکه نگاشت کنیم. آنها می‌تواند ارتباطات فضایی در داده و مفید بودن به‌همراه وظایف خوشه‌بندی بدون نظارت را حفظ کند. GWO می‌تواند پارامترهای فرعی SOM را برای دستیابی به ساختار شبکه با بهتری عملکرد کیفیت خدمات مورد استفاده قرار گیرد.

مدل شبکه شامل تعدادی حسگر یکنواخت است که به‌صورت تصادفی در یک منطقه استقرار یافته‌اند. ایستگاه پایه (BS) خارج از منطقه مورد نظر قرار دارد. هدف اصلی کمینه کردن مصرف انرژی و بیشینه کردن طول عمر شبکه است. برای یک شبکه IoT/WSN، شرایط زیر را به‌عنوان محدودیت‌ها در نظر می‌گیریم:

- مختصات (x, y) برای هر حسگر استقرار یافته از طریق سیستم موقعیت‌یابی GPS به ایستگاه پایه ارسال می‌شود.
 - تمامی دستگاه‌ها دارای باتری‌های شارژ شده‌اند و محدودیت انرژی دارند.
 - BS محدودیت انرژی ندارد.
 - مصرف انرژی به میزان فاصله بستگی دارد.
 - صلاحیت‌های مساوی برای اعضای شبکه در نظر گرفته شده است.
 - گره‌های حسگر قابلیت کنترل توان دارند.
- از خوشه‌بندی SOM، می‌توان به‌طور کارآمدی ناحیه تشخیصی کل را پوشش داد. ارسال و دریافت داده‌های شبکه با ایستگاه پایه از طریق نوروهای سطح اول سرخوشه انجام می‌شود. نمودار جریان شبکه عصبی مبتنی بر خوشه نمایانگر فرآیند کلی تشکیل SOM است. برای محاسبه فاصله نزدیک‌تر، از الگوریتم SOM استفاده می‌شود که از فاصله اقلیدسی برای جستجوی فعال‌سازی نوروها استفاده می‌کند. فاصله اقلیدوسی (D) بین یک نقطه داده (x) و برد وزنی نورو (w) معمولاً برای اندازه‌گیری شباهت استفاده می‌شود.

$$D(x, w) = s \sqrt{\sum_{i=1}^n (x_i - w_i)^2} \quad (8)$$

که x_i ویژگی i ام نقطه داده است، w_i ویژگی i ام بردار وزنی نورو است و n تعداد ویژگی‌ها است.

نگاشت بین داده‌های ورودی و نوروهای SOM و تخصیص خوشه‌ها در روش پیشنهادی به شرح زیر است: مجموعه داده‌های IoT/WSN که شامل خواندن‌های حسگر یا

خوشه‌بندی PSOKHM استفاده شده است. ساختار PSOKHM برای قرار دادن اجزای شبکه، یعنی اشیا در IoT، ارائه شده است. این ساختار دارای قابلیت مقیاس پذیری IoT است تا آن را به هر میزان در سطح شبکه گسترش دهد. ارتباطات مستقیم بین گره‌های رله و گره‌های حسگر در سطح خوشه، بار شبکه را از گره‌های محلی به گره‌های محلی رله مجهز می‌کند تا ارتباطات انرژی کارآمد را فراهم کند. ارتباط بین خوشه‌ای از طریق هماهنگ کننده خوشه، بار را از سرخوشه‌ها (در خوشه پایین تر) به هماهنگ کننده خوشه (در خوشه‌های بالا) بارگذاری می‌کند و در نتیجه طول عمر شبکه را افزایش می‌دهد.

عسگری و همکاران [۱۵] به ارائه روشی کارآمد جهت کاهش مصرف انرژی در مسیریابی اینترنت اشیا پرداختند. در این مقاله ابتدا یک دسته‌بندی کلی از مزایا و معایب این روش‌ها در حوزه مسیریابی اینترنت اشیا ارائه شده و سپس یک روش مسیریابی آگاه از کیفیت خدمات در مسیریابی مبتنی بر سیستم فازی پیشنهاد شده است.

۳- روش پیشنهادی

۳-۱- مدل شبکه روش پیشنهادی

کارایی انرژی و تاخیر از مهمترین موارد کیفیت خدمات در بسیاری از محیط‌های IoT هستند، به‌ویژه در مواردی که گره‌های حسگر منابع محدودی دارند یا در محیط‌های حساس به تاخیر و بلادرنگ فعالیت می‌کنند. برخی از این محیط‌ها شامل کشاورزی هوشمند، اینترنت اشیا صنعتی، اینترنت اشیا سلامت، نظارت بر محیط زیست، خانه هوشمند و شهر هوشمند می‌باشد. به‌عنوان مثال در اینترنت اشیا صنعتی در تولید و فرآیندهای صنعتی، حسگرها با نظارت ماشین‌آلات خطاها را تشخیص می‌دهند و تولید را بهینه می‌کنند. کاهش تاخیر می‌تواند باعث تصمیم‌گیری آنی و جلوگیری از توقف خط تولید گردد. علاوه بر این، خوشه‌بندی بهینه آگاه از انرژی می‌تواند نیاز به تعویض مکرر باتری در حسگرها را کمینه کند.

در خوشه‌بندی IoT/WSN، گره‌های حسگر بر اساس شباهت‌های داده‌ها یا موقعیت مکانی آنها خوشه‌بندی می‌شوند. رویکرد SOM-GWO می‌تواند به‌منظور کاهش مصرف انرژی در طول انتقال داده و پردازش آنها و کاهش تاخیر ارتباطی و امکان تجزیه و تحلیل داده بلادرنگ مورد استفاده قرار گیرد. SOMها با قابلیت سازگاری و انعطاف‌پذیری بالا می‌توانند به ما کمک کنند تا داده‌های

بزرگتر می‌تواند قدرت اکتشاف را افزایش دهد، اما ممکن است پیچیدگی محاسباتی را نیز افزایش دهد. اندازه جمعیت بر اساس سرعت همگرایی و تنوع راه‌حل‌های مشاهده شده در آزمایش‌های بهینه‌سازی تنظیم می‌شوند.

- شرایط خاتمه را برای الگوریتم GWO مانند حداکثر تعداد تکرار یا آستانه همگرایی می‌توان تعریف نمود. این معیارها تعیین می‌کنند که فرآیند بهینه‌سازی چه زمانی باید متوقف شود. معیارهای خاتمه را برای دستیابی به تعادل مناسب بین همگرایی و زمان محاسبه تنظیم می‌شوند.

معادله زیر انرژی کل مصرف شده توسط هر گره را هنگام انتقال (E_{tx}) و دریافت (E_{rx}) یک بسته داده L بیتی توصیف می‌کند. هر زمان که فاصله آستانه (d_0) بزرگتر از فاصله انتشار (d) باشد، مصرف انرژی گره متناسب با d^2 است.

$$E_{rx}(L) = L \times E_{elec} \quad (9)$$

$$\begin{aligned} \text{if } d < d_0 \\ E_{tx}(L, d) &= L \times E_{elec} + L \times \epsilon_{fs} \times d^2 \end{aligned} \quad (10)$$

$$\begin{aligned} \text{if } d \geq d_0 \\ E_{tx}(L, d) &= L \times E_{elec} + L \times \epsilon_{mp} \times d^4 \end{aligned}$$

که در آن E_{elec} انرژی تلف شده در هر بیت برای عملکرد مدار، یعنی فرستنده یا گیرنده، ϵ_{fs} انرژی تقویت کننده مدل فضای آزاد و ϵ_{mp} در مدل چند مسیری است و d_0 محدوده آستانه انتقال است. E_{elec} تحت تاثیر عوامل مختلفی از جمله مدولاسیون، کدگذاری دیجیتال، پخش سیگنال و فیلتر است. کل تلفات انرژی به صورت $E_{total} = E_{tx} + E_{rx}$ محاسبه می‌شود. علاوه بر این، مصرف انرژی جمع‌آوری داده‌های سرخوشه به صورت $E_{DA} = 5n \times |bit| \times msg$ محاسبه می‌شود [۱۶].

۳-۲- نمودار جریان روش پیشنهادی


نمودار جریان مدل SOM-GWO را برای خوشه‌بندی IoT/WSN در شکل (۲) نشان داده شده است.

ویژگی‌ها است به‌عنوان داده‌های ورودی در نظر گرفته می‌شوند. نورون‌ها در شبکه SOM، هر کدام نماینده یک نمونه خوشه هستند. هر نورون دارای یک بردار وزن با ابعاد مشابه داده‌های ورودی است. نقاط داده را بر اساس نورون برنده (نورونی که بردار وزن نزدیک‌تری دارد) به خوشه‌ها اختصاص داده می‌شوند.

در طول آموزش، SOM وزن‌های نورون‌ها را براساس نورون برنده و همسایه‌هایش به‌روز می‌کند. نرخ یادگیری (α) اندازه وزن‌ها را در به‌روزرسانی‌ها کنترل می‌کند و شعاع همسایگی (σ) میزان تاثیر به‌روزرسانی روی نورون‌های همسایه را تعیین می‌کند. متغیرهای تنظیم‌پذیر در شبکه SOM و الگوریتم GWO موارد زیر هستند.

- اندازه شبکه مشبکه^{۱۳} در SOM می‌تواند برای تطبیق تعداد خوشه‌ها در داده‌های IoT/WSN تنظیم شود. بایستی مشبکه با اندازه‌های مختلف آزمایش شود تا بهترین موردی را که ساختار داده‌های اساسی را نشان می‌دهد، پیدا نمود. مشبکه بزرگتر ممکن است جزئیات دقیق‌تر را ثبت کند، در حالی که مشبکه کوچکتر ممکن است منجر به خوشه‌های کلی‌تر شود.
- نرخ یادگیری (α) نرخ یادگیری مقدار گام به‌روزرسانی وزن‌ها در طول آموزش را کنترل می‌کند. می‌توان آن را برای کنترل نرخ همگرایی تنظیم نمود. نرخ یادگیری کمتر می‌تواند منجر به همگرایی کندتر شود، اما ممکن است نتایج پایدارتری را به همراه داشته باشد. نرخ یادگیری بالاتر می‌تواند همگرایی را تسریع کند، اما ممکن است خطر از دست دادن راه‌حل‌های بهینه را داشته باشد.
- شعاع همسایگی (σ) میزان تاثیر به‌روزرسانی روی نورون‌های همسایه را تعیین می‌کند. تنظیم این پارامتر تاثیر SOM بر روی الگوهای داده را تعیین می‌کند.
- تعداد دوره‌های آموزش یا تعداد تکرارهای آموزش می‌تواند کنترل همگرایی مدل SOM را تنظیم نماید.
- اندازه جمعیت در الگوریتم GWO تعداد گرگ‌های خاکستری یا راه‌حل‌های بالقوه را تعیین می‌کند که در طول بهینه‌سازی بررسی می‌شوند. اندازه جمعیت

¹³ Grid Size



شکل ۲- نمودار جریان شبکه عصبی SOM-GWO پیشنهادی

۳-۳- الگوریتم روش پیشنهادی

مراحل اجرای SOM-GWO به شرح زیر است.

الف. تشکیل خوشه‌ها

- مرحله ۱: مقداردهی اولیه نقشه

یک نقشه SOM دو بعدی ایجاد می‌شود و هر وزن شبکه به صورت تصادفی مقداردهی می‌شود. مختصات حسگرها (x, y) با استفاده از یک روش نرمال سازی $MIN - MAX$ به صورت داده شده در (۱۱) نرمال سازی می‌شوند.

$$V_{i,j} = (x_1, y_1, \dots, x_n, y_n) \quad (11)$$

$$v_{i,j} = \frac{v_{i,j} - MIN_j}{MAX_j - MIN_j}$$

که $v_{i,j}$ مقدار فعلی، MIN_j و MAX_j حداقل و حداکثر مقادیر در ستون بردار ورودی V هستند. مقادیر نرمال سازی

شده به عنوان یک بردار ورودی به نقشه داده می‌شوند. سپس مراحل زیر انجام می‌شوند.

- مرحله ۲: یافتن نورون برنده

برای هر بردار ورودی، ابتدا فاصله اقلیدسی بین بردار وزن هر گره W_i و بردار ورودی کنونی X_i محاسبه می‌شوند. بردار فعلی به همان خوشه که نورون برنده در آن قرار دارد تعلق دارد. فاصله اقلیدسی در (۱۲) نشان داده می‌شود.

$$d = \sqrt{\sum_{i=0}^n (X_i - W_i)^2} \quad (12)$$

سپس وزن‌های نزدیک به نورون برنده تنظیم می‌شوند. هرچه گره نزدیک‌تر به نورون برنده باشد، وزن‌های آن بیشتر تغییر می‌کند. این معادله از (۱۳) پیروی می‌کند.

$c = \operatorname{argmin}_{x \in \text{cluster}_i} (E(x))$ محاسبه می‌شود. اگر بیش از یک مرکز پیدا شود، مرکزی که از نظر سطح انرژی بالاتری برخوردار است، انتخاب می‌شود.

ج. فرآیند مسیریابی

بعد از اتمام فرآیند خوشه‌بندی، گره‌های عضو داده‌های جمع‌آوری شده را به سرخوشه مربوطه انتقال می‌دهند. به‌منظور بهبود کارایی انرژی مصرفی بر اساس خوشه، یک استراتژی چندگامه برای ارتباطات بین خوشه‌ای و داخلی به کار گرفته می‌شود. گره‌ها از ارتباط چندگامه بین گره‌های درونی استفاده می‌کنند. هر گره سرخوشه داده‌های تجمیع شده را از طریق یک استراتژی چندگامه به سمت ایستگاه پایه منتقل می‌کند. ارتباطات بین خوشه‌ای و درون خوشه‌ای با استفاده از مسیرهای حداقل انجام می‌شود.

د. به‌روزرسانی خوشه‌ها

هنگامی که آستانه مشخص شده به دست می‌آید، گره‌های شبکه انتقال داده را متوقف کرده و ایستگاه پایه شرایط تجدید خوشه‌بندی را تأیید می‌کند. براساس گره‌هایی که مرده‌اند یا به تازگی به شبکه پیوسته‌اند، BS تصمیم می‌گیرد که آیا شبکه را مجدداً خوشه‌بندی کند یا منتظر آستانه بعدی بماند.

۳-۱-۳- الگوریتم SOM-GWO

بهینه‌سازی GWO کارایی SOM را افزایش می‌دهد با پیدا کردن پارامترهای تنظیمی که منجر به نتایج بهتر خوشه‌بندی در زمینه بهره‌وری انرژی، تاخیر کمتر و کیفیت خوشه می‌شود. این فرآیند تنظیم پارامترهای تنظیمی را به‌صورت خودکار انجام می‌دهد و نیاز به تنظیم دستی پارامتر را کاهش می‌دهد. GWO می‌تواند به‌صورت کارآمد فضای پارامترهای تنظیمی را کاوش کند و پیکربندی‌های برتر ممکن است که توسط تنظیم دستی سخت‌افزاری از آنها پیدا کردن چالش‌برانگیز باشد. مراحل الگوریتم SOM-GWO به صورت زیر است.

۱. گام آغازین

مراحل زیر در این گام صورت می‌پذیرد.

- پارامترهای بهینه‌سازی گرگ خاکستری (GWO) از جمله تعداد گرگ‌ها (اندازه جمعیت)، حداکثر تکرارها و معیار همگرایی مقداردهی می‌شوند.
- پارامترهای نقشه خود سازمان ده (SOM) از جمله اندازه شبکه، نرخ یادگیری و شعاع همسایگی

$$\begin{aligned} w_{ij}(t+1) &= w_{ij}(t) + \Delta w_{ij}(t) \\ w_{ij}(t) &= \alpha(t) f_{ij}(g, h, \sigma(t)(x - w_{ij}(t)) \end{aligned} \quad (13)$$

که $\Delta w_{ij}(t)$ تغییری است که به $w_{ij}(t)$ اضافه می‌شود. t شماره دوره، g و h مختصات نورون برنده، $\alpha(t)$ نرخ یادگیری، $\sigma(t)$ شعاع و $f_{ij}(g, h, \sigma(t))$ تابع فاصله محلی است که در (۱۴) نشان داده شده است.

$$f_{ij}(g, h, \sigma(t)) = e^{-\frac{d((i,j),(g,h))^2}{2\sigma(t)^2}} \quad (14)$$

که $d((i,j),(g,h))$ فاصله مختصات (i,j) یک سلول از مختصات نورون برنده (g,h) است.

- مرحله ۳: تنظیم نرخ یادگیری و کاهش شعاع

کاهش نرخ یادگیری α و شعاع σ را مطابق (۱۵) محاسبه می‌شوند (به کمک پارامترهای تنظیم شونده λ و β). همچنین این مقادیر می‌توانند به‌صورت تصادفی برای جلوگیری از بهینگی محلی توسط GWO مقداردهی شوند.

$$\begin{aligned} \alpha(t) &= \alpha(t-1) \times e^{-t\lambda} \\ \sigma(t) &= \sigma(t-1) \times e^{-t\beta} \end{aligned} \quad (15)$$

در نهایت، مرحله ۲ و مرحله ۳ به تعداد $I_{\max}$ تکرار می‌شوند و هر بردار به گروه نورون برنده نهایی تعلق پیدا می‌کند.

ب. انتخاب سرخوشه

در پایان مرحله انتساب به خوشه، انتخاب سرخوشه انجام می‌شود. از آنجا که الگوریتم پیشنهادی بر مبنای استراتژی مسیریابی چندگامه است، تمایل به انتخاب گره با کوتاه‌ترین فاصله به همه‌ی جفت گره‌ها در خوشه بیشتر است، یعنی مرکز گراف. الگوریتم GWO می‌تواند برای تعیین مرکز خوشه و همچنین بهینه‌سازی پارامترهای SOM استفاده شود. مراحل به شرح زیر است.

برای هر دو گره x و y در یک خوشه، مقدار $\minDist(x,y)$ پیدا می‌شود که نشان‌دهنده طول کوتاه‌ترین مسیر از x به y است. اگر مسیری وجود نداشته باشد، این طول برابر با ∞ است. سپس مقادیر $E(x)$ برای تمام گره‌های خوشه پیدا می‌شوند. $E(x)$ فاصله یک گره را نمایش می‌دهد، یعنی بیشترین فاصله برای رفتن از گره x به تمامی دیگر گره‌های خوشه به‌صورت $E(x) = \max(\minDist(x,y))$ محاسبه می‌شود. گره c مرکز خوشه i را نشان می‌دهد و به‌صورت

- نقاط داده بر اساس محاسبات BMU به خوشه‌ها اختصاص می‌یابند.
- مقدار تابع هدف، معیاری از کیفیت خوشه‌بندی را ارائه می‌دهد.

۳-۲- الگوریتم بهینه‌سازی شعاع همسایگی، نرخ یادگیری و اندازه شبکه با استفاده از GWO

هدف بهینه‌سازی شعاع همسایگی (σ)، نرخ یادگیری (α) و اندازه شبکه برای نقشه خود سازمانده (SOM) در خوشه‌بندی IoT/WSN با استفاده از الگوریتم بهینه‌سازی گرگ خاکستری (GWO).

ورودی‌ها

- محدوده شعاع همسایگی اولیه $[\sigma_{min}, \sigma_{max}]$ (که σ شعاع همسایگی است).
- محدوده نرخ یادگیری اولیه $[\alpha_{min}, \alpha_{max}]$ (که α در آن نرخ یادگیری است).
- محدوده اولیه اندازه شبکه $[m_{min}, m_{max}]$ ، $[n_{min}, n_{max}]$ (که در آن m حداقل و حداکثر تعداد ردیف‌ها و n حداقل و حداکثر تعداد ستون‌هاست).
- بیشینه تکرارها $max_{iterations}$
- تابع تناسب $EvaluateParam(\sigma, \alpha, (m, n))$

خروجی‌ها

- شعاع همسایگی بهینه $\sigma_{optimal}$
- نرخ یادگیری بهینه $\alpha_{optimal}$
- اندازه بهینه شبکه $m_{optimal}$ ، $n_{optimal}$

گام‌های الگوریتم

یک جمعیت از گرگ‌های خاکستری (راه‌حل‌ها) را به‌طور تصادفی در محدوده مشخص شده، مقداردهی اولیه می‌شوند؛ پارامتر X از X_{min} تا X_{max} متغیر است.

۱. شایستگی (تناسب) هر گرگ خاکستری را با اعمال تابع تناسب به‌صورت $fitness = EvaluateParam(\alpha, \sigma, (m, n))$ ارزیابی می‌شود.

۲. گرگ‌های آلفا، بتا و دلتا با بهترین مقادیر تناسب در میان جمعیت شناسایی می‌شوند.

۳. شمارنده تکرار (iteration) مقدار اولیه ۱ را دریافت می‌کند.

۴. تا زمانی که $iteration \leq max_{iterations}$ تکرار صورت می‌پذیرد

مقداردهی می‌شوند.

- شبکه SOM و بردارهای وزن آن با مقادیر تصادفی مقداردهی می‌گردند.
- جمعیت اولیه گرگ‌های خاکستری در فضای جستجو ایجاد می‌شوند.

۲. آموزش

تا زمانی که معیار همگرایی برآورده نشود یا حداکثر تعداد تکرارها به پایان نرسد، تکرارهای GWO انجام می‌پذیرد. برای هر تکرار GWO داریم.

- تناسب هر گرگ خاکستری در جمعیت با استفاده از تابع هدف SOM ارزیابی می‌گردد. تابع هدف، کیفیت خوشه‌بندی را اندازه‌گیری می‌کند.
- رهبر (گرگ خاکستری با بهترین تناسب) شناسایی شده و موقعیت سایر گرگ‌های خاکستری با استفاده از گامهای اکتشافی و بهره‌برداری، الهام گرفته از رفتار گرگ‌ها، به روز می‌شوند.
- پارامترهای SOM (نرخ یادگیری و شعاع همسایه) بر اساس تکرارهای GWO یا قوانین خاص به روز می‌شوند.

۳. گام تشکیل خوشه

پس از آموزش SOM-GWO، شبکه SOM خوشه‌ها تشکیل می‌یابند، به‌طوری که هر نورون نشان دهنده مرکز یک خوشه است.

۴. گام اختصاص خوشه

نقاط داده به خوشه‌ها با پیدا کردن واحد بهترین تطابق (BMU) در شبکه SOM برای هر نقطه داده اختصاص داده می‌شود.

۵. تابع هدف

تابع هدف نهایی را برای کل مجموعه داده محاسبه کنید تا کیفیت خوشه‌بندی را بر اساس SOM آموزش دیده ارزیابی کنید.

۶. خروجی

خروجی این فرایند به شرح زیر است.

- شبکه SOM نهایی با بردارهای وزن، خوشه‌های تشکیل شده در طول فرآیند SOM-GWO را نشان می‌دهد.

$$F = w_1 \cdot \sum_{c \in C} L(c) + w_2 \cdot \sum_{c \in C} E(c) \quad (16)$$

که w_1 و w_2 عامل‌های وزنی هستند که تعیین کننده تعادل بین به حداقل رساندن تاخیر و مصرف انرژی هستند. این عامل‌ها به ما امکان می‌دهند اهمیت هر مؤلفه را بر اساس الزامات خاص برنامه کاربردی خود تنظیم کنیم. $\sum_{c \in C} L(c)$ مجموع میانگین تاخیرها در همه خوشه‌ها و $\sum_{c \in C} E(c)$ مجموع میانگین مصرف انرژی در همه خوشه‌ها را محاسبه می‌کند. بهینه‌سازی این تابع هدف با استفاده از رویکردهایی مانند بهینه‌سازی GWO در مدل SOM-GWO می‌تواند در یافتن یک پیکربندی خوشه‌بندی کارآمد موثر واقع شود.

۴- ارزیابی روش پیشنهادی

ارزیابی روش پیشنهادی و برتری آن با رویکردهای مقایسه‌شده در زیر نشان داده شده است.

۴-۱- محیط شبیه‌سازی

برای شبیه‌سازی پروتکل مسیریابی IoT/WSN از شبیه‌ساز پایتون استفاده می‌شود. در شبکه‌های حسگر بی‌سیم، مجموعه‌ای از پارامترها برای ارزیابی الگوریتم خوشه‌بندی وجود دارد. پارامترهای استفاده شده برای محاسبه انرژی در جدول ۱ نمایش داده شده است.

جدول ۱- پارامترهای شبیه‌سازی برای محاسبه انرژی	
پارامتر	مقدار
تعداد گره‌ها	100 – 500
تعداد سرخوشه‌ها	3 – 9
ناحیه	100 × 100 m ²
موقعیت BS	(50,100)
d_0	400 m
انرژی اولیه	0.5 J
E_{elec}	500 nJ/bit
ϵ_{fs}	10 pJ/bit/m ²
ϵ_{mp}	0.0013 pJ/bit/m ⁴
E_{DA}	5 nJ/bit/signal
اندازه بسته	4000 bits

استقرار گره‌ها می‌تواند بر عملکرد یک پروتکل داده‌شده تأثیر بگذارد. در این پژوهش از تابع توزیع تصادفی استفاده شده است. در شبیه‌سازی شبکه، مدل ترافیک داده عاملی حیاتی برای تعیین این است که چگونه وضعیت ترافیک،

الف. مقادیر a ، b و d (ضرایب به روز رسانی موقعیت) برای هر گرگ خاکستری بر اساس تناسب آنها در مقایسه با گرگ‌های آلفا، بتا و دلتا محاسبه می‌شوند.

ب. شعاع همسایگی، نرخ یادگیری و اندازه شبکه هر گرگ خاکستری را به روز می‌گردند

$$\alpha_{new} = \alpha + a \times (\alpha_{alpha} - \alpha)$$

$$\sigma_{new} = \sigma + a \times (\sigma_{alpha} - \sigma)$$

$$m_{new} = m + a \times (m_{alpha} - m)$$

$$n_{new} = n + b \times (n_{beta} - n)$$

ج. اطمینان حاصل می‌شود که مقادیر به روز شده در محدوده مشخص شده $X_{min} \leq X_{new} \leq X_{max}$ باقی می‌ماند.

د. تناسب شعاع همسایگی به روز شده هر گرگ خاکستری ($fitness_{new}$) به صورت زیر ارزیابی می‌شود.

$$EvaluateParam(\alpha_{new}, \sigma_{new}, (m_{new}, n_{new}))$$

ه. اگر $fitness_{new}$ بهتر از تناسب فعلی است، شعاع همسایگی و تناسب گرگ خاکستری به روز می‌شود.

و. گرگ‌های آلفا، بتا و دلتا با بهترین مقادیر تناسب را در میان موقعیت‌های به روز شده شناسایی کنید.

ز. شمارنده تکرار افزایش پیدا می‌کند، یعنی $iteration = iteration + 1$ شود.

۵. شعاع همسایگی و نرخ یادگیری با بهترین تناسب در میان گرگ‌های خاکستری به عنوان شعاع همسایگی بهینه برگزیده می‌شود $\alpha_{optimal}$ ، $\sigma_{optimal}$ و $m_{optimal}$

این الگوریتم با تنظیم در محدوده مشخص شده در حالی که مقدار شایستگی آن را ارزیابی می‌کند، به طور تکراری به دنبال شعاع همسایگی و نرخ یادگیری بهینه برای SOM می‌گردد.

۳-۳-۳- تابع هدف

فرض کنید C مجموعه خوشه‌های تشکیل شده توسط SOM باشد؛ D مجموعه داده‌های نقاط داده IoT باشد؛ $L(C)$ میانگین تاخیر خوشه C باشد (به عنوان مثال، میانگین زمانی که طول می‌کشد تا داده‌ها در داخل خوشه حرکت کنند)؛ $E(C)$ میانگین مصرف انرژی خوشه C باشد (به عنوان مثال، میانگین انرژی مصرف شده توسط حسگرها در داخل خوشه)؛ K تعداد کل خوشه‌های تشکیل شده توسط SOM باشد، تابع هدف F را می‌توان به صورت مجموع وزنی میانگین تاخیر و مصرف انرژی در سراسر همه خوشه‌ها تعریف کرد.

ورود و مدت زمان تاثیرگذاری بر مصرف انرژی را تعیین می‌کند. در پژوهش حاضر، مدل مبتنی بر زمان^{۱۴} برای تجزیه و تحلیل رفتار ترافیک داده استفاده می‌شود، که تعداد دقیق گره‌های انتقالی را می‌شناسد. این مدل مناسب هر شبکه ارتباطی با پهنای باند ثابت است.

جدول پارامتر GWO، SOM و ترکیب آنها SOM-GWO، مرحله ارزشمندی در تنظیم شبیه‌سازی برای خوشه‌بندی IoT است. در زیر (جدول ۲)، پارامترهای این دو الگوریتم توضیح داده شده است.

جدول ۲- پارامترهای شبیه‌سازی SOM و GWO

الگوریتم	پارامتر	توضیحات	مقادیر
GWO	اندازه جمعیت (N)	تعداد گره‌های خاکستری در جمعیت	10
	حداکثر تکرارها (max _{iter})	حداکثر تعداد تکرارهای GWO	100
	معیار همگرایی	معیار خاتمه دادن به GWO	همگرایی
	عامل اکتشاف (a)	اکتشاف را در طول GWO کنترل می‌کند (معمولاً در محدوده [0,1])	$\Delta F < 0.001$
	عامل بهره‌برداری (A)	بهره‌برداری را در طول GWO کنترل می‌کند (معمولاً در محدوده [0,2])	0.5
			1.5
SOM	اندازه شبکه ($m \times n$)	ابعاد شبکه SOM	10×10
	نرخ یادگیری (α)	سرعت به روز رسانی بردارهای وزن در SOM را تعیین می‌کند.	0.1
	شعاع همسایگی (σ)	دامنه نوروهای همسایه را در طول آموزش تحت تاثیر قرار می‌دهد.	1.0
GWO-SOM	عامل وزنی برای تاخیر (w_1)	تعادل بین تاخیر و مصرف انرژی در تابع هدف	0.6
	عامل وزنی برای انرژی (w_2)	تعادل بین تاخیر و مصرف انرژی در تابع هدف	0.4

عامل‌های اکتشاف و بهره‌برداری را می‌توان برای کنترل تعادل بین جستجوی سراسری و بهینه‌سازی محلی تنظیم کرد. اندازه شبکه SOM باید بر اساس تعداد نقاط داده و سطح مطلوب جزئیات در نتایج خوشه‌بندی انتخاب شود. نرخ یادگیری و شعاع همسایگی باید برای دستیابی به همگرایی خوب و جلوگیری از برازش بیش از حد تنظیم شوند. عامل‌های وزنی برای تاخیر و مصرف انرژی را می‌توان برای اولویت‌بندی یک هدف نسبت به دیگری، بسته به نیازهای خاص تنظیم نمود.

۲-۴- یافته‌ها

در اینجا، عملکرد رویکرد پیشنهادی با پروتکل‌های


خوشه‌بندی و مسیریابی موجود LEACH [۱۷]، HEED [۱۸]، SOM-LEACH [۱۹] و EESOM [۱۶] مقایسه می‌شود. خوشه‌بندی SOM در شکل (۳) نشان داده شده است. پارامترهای عملکرد طول عمر سیستم، توان عملیاتی، مصرف انرژی، نرخ خطای بیت، اشغال بافر، تاخیر انتها به انتها (E2ED) و نسبت تحویل بسته (PDR) با استفاده از ۵۰۰ گره در مقایسه با سایر روش‌های موجود محاسبه می‌شوند. این شبیه‌سازی‌ها ۱۰۰ گره حسگر همگن و ۹ گره سرخوشه را در فضایی به ابعاد 100×100 متر مربع قرار می‌دهند.

شکل (۴) فرایند توزیع گره‌های IoT قبل و پس از خوشه‌بندی را نشان می‌دهد.


¹⁴ time-triggered



شکل ۳- عملکرد SOM در خوشه‌بندی




(ب)



(الف)

شکل ۴- محیط شبکه IoT (الف) قبل از خوشه‌بندی (ب) پس از خوشه‌بندی



شکل ۵- تعداد گره‌ها در مقابل نسبت تحویل بسته


۴-۲-۲-۴- توان عملیاتی

توان عملیاتی نسبت تعداد بسته‌های دریافتی در گیرنده به مدت زمان ارسال بسته است. شکل (۶) روش‌های پیشنهادی و عملکرد توان عملیاتی روش‌های موجود را نشان می‌دهد. شکل به وضوح نشان می‌دهد که تکنیک پیشنهادی از نظر بیانی بهبود یافته است. همانطور که در

بر اساس طرح جمع‌آوری داده‌های پیشنهادی، عملکرد شبکه از نظر PDR، توان عملیاتی، تاخیر، انرژی کل و سرعت شبیه‌سازی شد.

۴-۲-۱- نرخ تحویل بسته


نرخ تحویل بسته نسبت بسته‌های دریافتی در گیرنده به بسته‌های ارسال شده توسط فرستنده است. شکل ۵ ارزیابی PDR طرح‌های موجود و پیشنهادی را نشان می‌دهد. این شکل نشان می‌دهد که سیستم پیشنهادی نسبت به سایر طرح‌ها پیشرفته‌تر است. در مقایسه با سایر سیستم‌ها، روش پیشنهادی به PDR بالا (۹۷ درصد) دست می‌یابد. افزایش تعداد گره حسگر باعث کاهش PDR می‌شود. PDR تکنیک‌های موجود LEACH، HEED، SOM-LEACH و EESOM به‌طور میانگین به‌صورت جداگانه ۸۹، ۹۲ و ۹۶ درصد است. مقایسه نسبت تحویل بسته در شکل (۵) نشان داده شده است. پروتکل LEACH بیش‌ترین کاهش و رویکرد SOM-GWO پیشنهادی کمترین تاخیر را در نسبت تحویل بسته دارد.



شکل ۸- تعداد سرخوشه‌ها در مقابل انرژی مصرفی (mJ)

۴-۲-۴- تاخیر انتها به انتها


شکل (۹) تجزیه و تحلیل تاخیر انتها به انتها (E2ED) را برای روش پیشنهادی و روش‌های موجود بیان می‌کند. روش پیشنهادی کمترین (۸ میلی‌ثانیه برای ۵۰۰ گره) E2ED نسبت به سایر طرح‌های فعلی به دست آورد. اگر تعداد گره‌ها افزایش یابد، E2ED افزایش می‌یابد. رویکردهای موجود LEACH، HEED، SOM-LEACH و EESOM به ترتیب ۹/۵، ۹/۲، ۸ و ۷/۸ میلی ثانیه است. رویکرد پیشنهادی به‌طور میانگین ۲۵٪ عملکرد بهتری را نسبت به SOM-LEACH و EESOM داشته است.



شکل ۹- تعداد گره‌ها در مقابل تاخیر انتها به انتها

شکل (۱۰) میزان تاخیر انتها به انتها به ازای تعداد سرخوشه‌ها (۳ تا ۱۱) را نشان می‌دهد. همانطور که در شکل نشان داده شده است با افزایش تعداد سرخوشه‌ها، میزان تاخیر به‌طور قابل توجهی افزایش داشته است (به‌طور خاص در روش پیشنهادی ۵ تا ۸ میلی‌ثانیه). این رفتار نشان می‌دهد که باید بین تعداد سرخوشه‌ها، مصرف انرژی و تاخیر انتها به انتها، با توجه به نیاز شبکه، توازن را برقرار نمود.

شکل (۶) نشان داده شده است، مدل پیشنهادی از نظر توان عملیاتی بهتر از راه‌حل‌های موجود عمل کرد.




شکل ۶- تعداد گره‌ها در مقابل توان عملیاتی (bps)

۴-۲-۳- انرژی مصرفی


مصرف انرژی به‌صورت مجموع انرژی دریافتی، انرژی ارسالی و تعداد گره‌ها تعریف می‌شود. شکل (۷) مصرف کلی انرژی طرح پیشنهادی را در مقایسه با سایر طرح‌های موجود نشان می‌دهد. در مقایسه با سایر روش‌های موجود، فناوری ایجاد شده انرژی کمتری (۱۳۰ میلی ژول) در ۵۰۰ گره مصرف می‌کند. نمودار نشان می‌دهد که چگونه روش برنامه‌ریزی شده در مقایسه با روش‌های دیگر به وضوح برتری دارد. مقدار افزایش گره‌های IoT مقدار انرژی مصرف شده را افزایش می‌دهد. پروتکل‌های LEACH، HEED، SOM-LEACH و EESOM موجود به ترتیب ۱۸۰، ۲۱۰، ۲۲۵ و ۱۴۰ میلی ژول انرژی مصرف می‌کنند.

شکل (۸) میزان مصرف انرژی به ازای تعداد سرخوشه‌ها (۳ تا ۱۱) را نشان می‌دهد. همانطور که در شکل نشان داده شده است با افزایش تعداد سرخوشه‌ها، میزان مصرف انرژی به‌طور قابل توجهی کاهش داشته است (به‌طور خاص در روش پیشنهادی ۱۰۰ تا ۵۵ میلی‌ژول). زوش پیشنهادی به میزان ۱۱ درصد نسبت به روش EESOM عملکرد بهتری از منظر انرژی مصرفی داشته است.



شکل ۷- تعداد گره‌ها در مقابل مصرف انرژی (mJ)


تعداد گره‌ها در سیستم، طول عمر سیستم کاهش می‌یابد.



شکل ۱۲- تعداد خوشه‌ها در مقابل ارزیابی طول عمر شبکه


۷-۲-۴- تحلیل زمان

این مقدار کلی زمان صرف شده برای ایجاد خوشه و انتخاب CH را نشان می‌دهد. شکل (۱۳) عملکرد روش خوشه سازی را در طول زمان نشان می‌دهد. در این پژوهش، روش پیشنهادی برای ایجاد خوشه نسبت به روش‌های موجود زمان بیشتری برای اجرا داشت. چرا که پیچیدگی محاسبات و انتخاب سرخوشه کمی به محاسبات بیشتری نیازمند است. با افزایش تعداد خوشه‌ها این زمان افزایش می‌یابد. استراتژی پیشنهادی به زمان اجرای کمتری (۹۰ ثانیه) نسبت به SOM-LEACH و EESOM دست یافت. با این وجود، رویکرد HEED LEACH به زمان کمتری برای استقرار خوشه‌ها و فرایند بازسازی خوشه‌ها نیاز دارند.



شکل ۱۳- مقایسه زمان انتخاب سرخوشه


در پایان، مشاهده شد که رویکرد پیشنهادی مقدار بهتری از انرژی مصرف می‌کند، به عبارت دیگر کمترین مقدار انرژی را نسبت به روش‌های دیگر نیاز دارد. SOM-GWO استراتژی ارتباط چندگانه میان و داخل خوشه‌ها استفاده می‌کند که امکان صرفه‌جویی قابل توجهی از نظر انرژی را فراهم می‌کند زیرا مسافت ارسال هر گره CH و هزینه آن



شکل ۱۰- تعداد سرخوشه‌ها در مقابل تاخیر انتها به انتها

۵-۲-۴- اشغال بافر

شکل (۱۱) اشغال کلی بافر طرح پیشنهادی را در مقایسه با سایر طرح‌های موجود نشان می‌دهد. در مقایسه با سایر رویکردهای موجود، فناوری ایجاد شده از اشغال بافر کمتری (۹/۵) در ۵۰۰ گره استفاده می‌کند. این نمودار نشان می‌دهد که چگونه روش پیشنهاد شده در مقایسه با روش‌های دیگر به وضوح برتری دارد. اگر تعداد گره‌ها افزایش یابد، اشغال بافر افزایش می‌یابد. پروتکل‌های LEACH, HEED, SOM-LEACH و EESOM موجود به ترتیب ۲۶، ۲۰، ۱۴.۵ و ۱۱ درصد را اشغال می‌کنند.



شکل ۱۱- تعداد گره‌ها در مقابل اشغال بافر

۶-۲-۴- طول عمر شبکه

طول عمر سیستم مدت زمانی است که می‌تواند کار کند و در طی آن می‌تواند کار (های) اختصاص داده شده را انجام دهد. شکل (۱۲) عملکرد روش پیشنهادی و تکنیک موجود را در طول عمر یک شبکه مقایسه می‌کند. نمودار بالا نشان می‌دهد که استراتژی پیشنهادی نسبت به روش‌های موجود، طول عمر سیستم بیشتری (۵۴۰۰ دور) دارد. با افزایش

می‌توان پیکربندی‌های جایگزین برای رویکرد خوشه‌بندی مبتنی بر SOM-GWO خود را بررسی نمود. توپولوژی‌های مختلفی از شبکه‌های عصبی مانند RBF و ANFIS می‌توانند مورد استفاده قرار گیرند. علاوه بر این، معیارهای مختلفی برای انتخاب سرخوشه می‌توانند برای بهبود تابع هزینه پیشنهادی استفاده شوند. همچنین توابع همسایگی مختلف می‌توانند برای بهینه‌سازی خودسازمانی خوشه‌بندی و طرح‌های شبکه عصبی مورد استفاده قرار گیرند. در نهایت انطباق الگوریتم پیشنهادی در پروتکل‌های خوشه‌بندی توزیع شده (پروتکل پیشنهادی یک پروتکل متمرکز است که در آن تشکیل خوشه‌ها توسط ایستگاه مبنا انجام می‌شود) می‌تواند یک وظیفه چالش‌انگیز باشد.

تقدیر و تشکر

با تشکر از دانشگاه آزاد اسلامی که بستر مناسبی برای انجام پژوهش توسط دانشجویان خارجی فراهم نمود.

تعارض منافع

نویسندگان اعلام می‌کنند که در مورد انتشار این مقاله تعارض منافع وجود ندارد.

تاییدیه اخلاقی

نویسندگان متعهد می‌شوند که مطالب این مقاله را در هیچ جای دیگری به چاپ نرسانده‌اند.

مشارکت‌های نویسندگان

مرتضی جابر عبید البو جاسم: پیاده سازی الگوریتم با نرم‌افزار، پردازش داده‌ها، ویرایش و بررسی پیش‌نویس اصلی، منابع.

مهدی مزینانی: روش شناسی، نوآوری، بازبینی پردازش داده‌ها و ارزیابی آن، بازبینی پیش‌نویس اصلی و تهیه نسخه نهایی، اعتبارسنجی، تجزیه و تحلیل داده و توابع، راهنمایی. **عباس کوچاری:** نظارت، بازبینی پردازش داده‌ها، و ارزیابی، بازبینی پیش‌نویس اصلی، اعتبارسنجی، تجزیه و تحلیل داده، مشاوره.

منابع مالی:

در انجام پژوهش هیچ منبع مالی از طرف سازمان یا پژوهشگاه دریافت نگردیده‌است.

را کاهش می‌دهد و مسیر کوتاه‌تر بین تمام اعضای خوشه را برای هر گره به سمت CH خود و هزینه آن در نظر می‌گیرد. از این تاخیر انتها به انتها کمتری را نسبت به رویکردهای مقایسه شده دارد.

۵- نتیجه گیری

در IoT/WSN، بسیاری از گره‌های حسگر مناطق وسیعی را به دست می‌آورند و به سرعت بر برنامه‌های امنیتی و تجاری در زمان واقعی تأثیر می‌گذارند. در این پژوهش، مسئله خوشه‌بندی بر اساس مسیریابی در شبکه‌های حسگر بی‌سیم / اینترنت اشیا با هدف کاهش مصرف انرژی و حفظ پوشش شبکه مورد تمرکز قرار گرفت. در این راستا، شبکه عصبی خودسازمانده (SOM) برای ارائه پروتکل خوشه‌بندی بر پایه انرژی مورد استفاده قرار گرفت. هدف اصلی، تا جای ممکن افزایش کارایی انرژی است تا شبکه به مدت طولانی‌تری ادامه یابد. در اینجا یک پروتکل مسیریابی سلسله مراتبی بر پایه خوشه‌بندی مبتنی بر مسیریابی طراحی کردیم، که پروتکل SOM-GWO نام گذاری شده است و با استفاده از الگوریتم بهینه‌سازی گرگ خاکستری (GWO) پارامترهای شبکه عصبی SOM را بهینه می‌سازد. پروتکل پیشنهادی موقعیت گره‌های حسگر، انرژی باقیمانده هر گره، فاصله بین گره‌ها و تاخیر سراسری را در نظر می‌گیرد و عمر شبکه را طولانی‌تر می‌کند. بر اساس تجزیه و تحلیل عملکرد مقایسه‌ای با رویکردهای پیشین، می‌توان نتیجه گرفت که پروتکل SOM-GWO پیشنهادی مصرف انرژی کمتری دارد و عمر شبکه بهبود یافته‌تری نسبت به روش‌های پیشین را فراهم می‌کند. برای کاهش ترافیک شبکه ناشی از اشغال بافر، سیستم پیشنهادی گره‌های جمع‌آوری داده پیوند قابل اعتماد را قادر می‌سازد و معیارهای خدماتی مانند توان عملیاتی، PDR، نرخ خطای بیت و تاخیر انتها به انتها را بهبود می‌بخشد. در مقایسه با پروتکل‌های HEED، LEACH، SOM-LEACH و EESOM، پروتکل پیشنهادی SOM-GWO طول عمر شبکه را بهبود داده است. برخی از پیشنهادها خاص برای تکرار و تنظیم دقیق رویکرد خوشه‌بندی پیشنهادی آورده شده است:

مراجع

- [1] Shende, Dipali K, S.S. Sonavane, and Yogesh Angal. "A comprehensive survey of the routing schemes for IoT applications." *Scalable Computing: Practice and Experience* 21, no. 2 (2020): 203-216.
- [2] Al-Karaki, Jamal N, and Ahmed E. Kamal. "Routing techniques in wireless sensor networks: a survey." *IEEE Wireless Communications* 11, no. 6 (2004): 6-28.
- [3] Cordina, Mario, and Carl J. Debono. "Increasing wireless sensor network lifetime through the application of SOM neural networks." In *2008 3rd International Symposium on Communications, Control and Signal Processing*, pp. 467-471. IEEE, 2008.
- [4] Mirjalili, Seyedali, Seyed Mohammad Mirjalili, and Andrew Lewis. "Grey wolf optimizer." *Advances in Engineering Software* 69 (2014): 46-61.
- [5] Kulakov, Andrea, Danco Davcev, and Goran Trajkovski. "Application of wavelet neural-networks in wireless sensor networks." In *Sixth International Conference on Software Engineering, Artificial Intelligence, Networking and Parallel/Distributed Computing and First ACIS International Workshop on Self-Assembling Wireless Network*, pp. 262-267. IEEE, 2005.
- [6] Oldewurtel, Frank, and Petri Mahonen. "Neural wireless sensor networks." In *2006 International Conference on Systems and Networks Communications (ICSNC'06)*, pp. 28-28. IEEE, 2006.
- [7] Merah, Malha, Zibouda Aliouat, and Mohamed Sofiane Batta. "A hybrid neural network and graph theory based clustering protocol for dynamic iot networks." In *2022 International Conference on Advanced Aspects of Software Engineering (ICAASE)*, pp. 1-7. IEEE, 2022.
- [8] Shen, Yan, and Xunbo Li. "Wavelet neural network approach for dynamic power management in wireless sensor networks." In *2008 International Conference on Embedded Software and Systems*, pp. 376-381. IEEE, 2008.
- [9] Salcedo-Sanz, Sancho, and Xin Yao. "A hybrid Hopfield network-genetic algorithm approach for the terminal assignment problem." *IEEE Transactions on Systems, Man, and Cybernetics, Part B (Cybernetics)* 34, no. 6 (2004): 2343-2353.
- [10] Sing, Ranumayee, Sourav Kumar Bhoi, Niranjan Panigrahi, Kshira Sagar Sahoo, Nz Jhanjhi, and Mohammed A. AlZain. "A whale optimization algorithm based resource allocation scheme for cloud-fog based IoT applications." *Electronics* 11, no. 19 (2022): 3207.
- [11] Kumar, Sumit, Virender Kumar, Saket Kumar Choudhary, Alireza Salamat, and Rubén González Crespo. "Comparative study on ant colony optimization (ACO) and K-means clustering approaches for jobs scheduling and energy optimization model in internet of things (IoT)." *IJIMAI* 6, no. 1 (2020): 107-116.
- [12] Kumar, Sushil, Omprakash Kaiwartya, Manisha Rathee, Neeraj Kumar, and Jaime Lloret. "Toward energy-oriented optimization for green communication in sensor enabled IoT environments." *IEEE Systems Journal* 14, no. 4 (2020): 4663-4673.
- [13] Khosravi, Mohammad Reza, Mohammad Kazem Moghimi, and Habib Rostami. "A Review of Energy-Aware Routing Methods Based on Physical Partitioning in Dense Acoustic Sensor Networks and Underwater Internet of Things" *Journal of Marine Science and Technology* 25, no.4 (2021). (in Persian)
- [14] Sarlak, Amir, and Hossein Mohammadi Nejad. "Routing to Reduce Energy Consumption in the Internet of Things by PSOKHM Clustering." In *Fourth International Conference on Interdisciplinary Research in Electrical Engineering, Computer Science, Mechanics, and Mechatronics in Iran and the Islamic World*, Tehran, Iran, 2020. (in Persian)
- [15] Asgari, Maryam, Mahmoud Fathi, Mohammad Shahvardi, and Mahmoud Soheili Niyr. "An efficient method for reducing energy consumption in Internet of Things routing" In *Electrical Engineering and Computer Engineering in Iran*, Tehran, Iran, 2019. (in Persian)
- [16] Merah, Malha, Zibouda Aliouat, and Chafia Kara-Mohamed. "An energy efficient self organizing map based clustering protocol for iot networks." In *2022 IEEE 9th International Conference on Sciences of Electronics, Technologies of Information and Telecommunications (SETIT)*, pp. 197-203. IEEE, 2022.
- [17] Heinzelman, Wendi Rabiner, Anantha Chandrakasan, and Hari Balakrishnan. "Energy-efficient communication protocol for wireless microsensor networks." In *Proceedings of the 33rd Annual Hawaii International Conference on System Sciences*, pp. 10-pp. IEEE, 2000.

- [18] Younis, Ossama, and Sonia Fahmy. "HEED: a hybrid, energy-efficient, distributed clustering approach for ad hoc sensor networks." *IEEE Transactions on Mobile Computing* 3, no. 4 (2004): 366-379.
- [19] Nayak, Padmalaya, G.K. Swetha, Priyanka Kaushal, and D.G. Padhan. "Cluster formation algorithm in wsns to optimize the energy consumption using self-organizing map." In *IoT and Analytics for Sensor Networks: Proceedings of ICWSNUCA 2021*, pp. 11-22. Springer Singapore, 2022.