



دانشگاه کاشان
University of Kashan

مجله محاسبات نرم

SOFT COMPUTING JOURNAL

تارنمای مجله: scj.kashanu.ac.ir



الگوریتم مسیریابی نوین برای شبکه‌های حسگر بی‌سیم زیر آب با استفاده از یادگیری تقویتی و شبکه‌های عصبی متخاصم زایشی

نوید کرمی بنماران¹، دانشجوی کارشناسی ارشد، نستوه طاهری جوان^{1*}، استادیار
¹ گروه مهندسی کامپیوتر، دانشکده فنی و مهندسی، دانشگاه بین‌المللی امام خمینی (ره)، قزوین، ایران.

چکیده

شبکه‌های حسگر بی‌سیم زیر آب با چالش‌هایی مانند محدودیت انرژی گره‌ها، حرکت حسگرها در اعماق مختلف و نیاز به روش‌های ارتباطی متنوع مواجه هستند. این محدودیت‌ها باعث کاهش کارایی الگوریتم‌های مسیریابی مرسوم در سایر شبکه‌های بی‌سیم چندگامه در این نوع از شبکه‌ها می‌شوند. در این پژوهش، یک روش مسیریابی نوین مبتنی بر یادگیری تقویتی و شبکه‌های عصبی متخاصم زایشی برای کاربرد در شبکه‌های حسگر بی‌سیم زیر آب معرفی می‌شود. هدف اصلی در این رویکرد، کشف و ذخیره مسیرهای مناسب برای ارسال داده‌ها است. سپس، با استفاده از الگوی شبکه‌های عصبی متخاصم زایشی (GAN)، این مسیرها برای آموزش یک مدل یادگیری عمیق بکار گرفته می‌شوند و سعی بر تولید مسیرهای جدید در این چرخه است. نتایج شبیه‌سازی نشان می‌دهند که استفاده از این رویکرد به بهبود نرخ تحویل موفق بسته‌ها به مقصد و افزایش طول عمر شبکه نسبت به روش‌های یادگیری تقویتی سنتی در شبکه‌های حسگر زیر آب منجر می‌شود.

اطلاعات مقاله

تاریخچه مقاله:

دریافت 9 آبان ماه 1403

پذیرش 2 اسفند ماه 1403

کلمات کلیدی:

شبکه‌های حسگر بی‌سیم زیر آب
مسیریابی
یادگیری تقویتی
یادگیری عمیق
شبکه عصبی متخاصم زایشی

© 1403 نویسندگان. مقاله با دسترسی آزاد تحت مجوز CC-BY

1. مقدمه

شبکه‌های حسگر بی‌سیم زیر آب استفاده می‌شود. این شبکه‌ها شامل حسگرهای متصل به باتری و وسایل نقلیه خودران هستند که در اعماق مختلف دریا قرار گرفته و داده‌ها را با استفاده از امواج صوتی جمع‌آوری می‌کنند. هدف اصلی این شبکه‌ها، جمع‌آوری پیوسته داده‌ها و ایجاد مسیرهای موثر برای تبادل اطلاعات است تا پوشش کاملی از منطقه تحت نظارت فراهم شود [3].

پایه‌سازی شبکه‌های حسگر بی‌سیم زیر آب در عمل با چالش‌های متعددی روبرو است. از جمله این چالش‌ها، نوع ارتباط متفاوت گره‌ها (استفاده از امواج صوتی)، محدودیت انرژی حسگرها، و تحرک گره‌ها در اعماق مختلف با فشارهای

کاربردهای اینترنت اشیا در سال‌های اخیر رشد قابل توجهی داشته است [1]. در این میان، شبکه‌های حسگر بی‌سیم به طور گسترده‌ای مورد استفاده قرار می‌گیرند [2] و یکی از مهم‌ترین شاخه‌های آنها، شبکه‌های حسگر بی‌سیم زیر آب است. اقیانوس‌ها و دریاها بیش از 90 درصد از آب زمین را تشکیل می‌دهند و نقش حیاتی در حفظ زندگی موجودات زنده دارند. برای جمع‌آوری داده‌های مربوط به شرایط محیطی زیر آب، از

* نوع مقاله: پژوهشی

* نویسنده مسئول

پست(های) الکترونیک: navid.karami@eng.ikiu.ac.ir (کرمی بنماران)

nastoooh@eng.ikiu.ac.ir (طاهری جوان)

نحوه ارجاع به مقاله: نوید کرمی بنماران، نستوه طاهری جوان، «الگوریتم مسیریابی نوین برای شبکه‌های حسگر بی‌سیم زیر آب با استفاده از یادگیری تقویتی و شبکه‌های عصبی متخاصم زایشی»، مجله محاسبات نرم، جلد 14، شماره 2، ص 113-96، پاییز و زمستان 1404.

متفاوت آب است [4]. این محدودیت‌ها منجر به ارائه راه‌حل‌های متنوعی برای بهبود عملکرد در لایه‌های مختلف معماری شبکه شده‌اند. یکی از مهم‌ترین موضوعات در این شبکه‌ها که به بهبود کارایی آنها در جنبه‌های مختلف کمک می‌کند، پروتکل‌های مسیریابی است. پروتکل‌های مسیریابی برای شبکه‌های حسگر بی‌سیم زیر آب باید بتوانند مقیاس‌پذیری، بهره‌وری انرژی، طول عمر شبکه و سرعت همگرایی را تضمین کنند. هدف اصلی این پروتکل‌ها، افزایش طول عمر شبکه با ارائه مسیرهای بهینه و کاهش مصرف انرژی است [5].

کارایی الگوریتم‌های مسیریابی در شبکه‌های حسگر بی‌سیم زیر آب تحت تاثیر عوامل متعددی قرار دارد، از جمله هزینه‌های جستجوی همسایه، هزینه‌های ارتباطی و هزینه‌های محاسباتی. به همین دلیل طراحی پروتکل‌های مسیریابی مخصوص برای شبکه‌های صوتی زیر آب با چالش‌های خاصی مواجه است [6]. برای مثال، کانال‌های زیر آب دارای ویژگی‌های منحصر به فردی مانند تضعیف بالا، پهنای باند محدود، و ناپایداری هستند. همچنین، حسگرها دارای باتری‌های محدودی هستند و به دلیل فرارگیری در زیر آب، از منابعی مانند انرژی خورشیدی برای شارژ مجدد محروم‌اند. علاوه بر این، ارتباطات زیر آب نسبت به ارتباطات رادیویی در خشکی انرژی بیشتری مصرف می‌کنند. بنابراین، بهبود پروتکل‌های مسیریابی با در نظر گرفتن این چالش‌ها می‌تواند به بهبود کارایی این شبکه‌ها کمک کند [7]. راه‌حل‌های ارائه شده در این زمینه به طور معمول محدود به بهبود یک پارامتر خاص و استفاده از رویکردهای سنتی هستند. اما با تعریف دقیق مسائل تصمیم‌گیری در گره‌ها و در نظر گرفتن چالش‌های مذکور، می‌توان به نتایج بهتری دست یافت [8]. در این مقاله، ما با استفاده از مدل‌سازی مساله به کمک مدل تصمیم‌گیری مارکوف و بکارگیری رویکرد یادگیری تقویتی، یک راهکار جدید برای مسیریابی در محیط‌های تصادفی شبکه‌های حسگر بی‌سیم زیر آب ارائه کرده‌ایم.

در رویکرد پیشنهادی، عامل یادگیرنده در نقاط تصمیم‌گیری تلاش می‌کند تا پاداش تجمعی خود را به حداکثر برساند. برای این منظور، مساله به گونه‌ای مدل‌سازی شده که عامل با

تصمیم‌گیری‌های مناسب در جهت بهبود کارایی شبکه، پاداش مثبت و در غیر این صورت، پاداش منفی دریافت می‌کند. پس از یافتن سیاست بهینه، عامل فرآیند یادگیری را کامل می‌کند.

برای بهبود عملکرد الگوریتم مسیریابی در رویکرد پیشنهادی، از شبکه عمیق متخاصم زایشی (GAN)¹ در طول فرآیند یادگیری استفاده می‌شود [9]. شبکه عصبی عمیق متخاصم زایشی نوعی شبکه عصبی است که برای تولید داده‌های جدید مشابه داده‌های واقعی بکار می‌رود. این الگوریتم شامل دو شبکه عصبی مجزا است. یکی شبکه مولد که وظیفه تولید داده‌های جدید مشابه داده‌های واقعی را بر عهده دارد و دیگری شبکه متمایزکننده که به تشخیص داده‌های واقعی از داده‌های جعلی تولید شده توسط مولد می‌پردازد. این دو شبکه در رقابتی خصمانه با یکدیگر عمل می‌کنند؛ شبکه مولد سعی می‌کند داده‌هایی ایجاد کند که بتواند متمایزکننده را فریب دهد، در حالی که متمایزکننده تلاش می‌کند داده‌های واقعی را از جعلی تشخیص دهد [10].

در رویکرد مسیریابی پیشنهادی، شبکه متخاصم با استفاده از اطلاعات گراف همسایگی حسگرها، مسیرهای واقعی موجود را ارائه می‌دهد که این امر موجب بهبود الگوریتم مسیریابی و جلوگیری از پیمایش مسیرهای غیرواقعی می‌شود. در این الگوریتم دو نوع چرخه وجود دارد. چرخه اول که در آن گره حسگر بدون دانش قبلی از شبکه متخاصم درخواست مسیریابی می‌کند و به طور تصادفی یکی از مسیرهای پیشنهادی را انتخاب می‌کند؛ سپس، ارزش مسیر و پاداش‌ها محاسبه و به GAN بازخورد داده می‌شود. در چرخه دوم، گره با توجه به تجربیات قبلی و دانش کسب شده، یکی از مسیرها را انتخاب می‌کند و پس از ارسال بسته، بازخوردی مشابه به GAN و گره‌ها ارسال می‌گردد. تفاوت اصلی این دو چرخه در کسب تدریجی دانش توسط گره حسگر است. مشارکت و نوآوری‌های مقاله حاضر را به شرح زیر می‌توان خلاصه کرد:

- ارائه یک الگوریتم مسیریابی مبتنی بر یادگیری تقویتی در شبکه‌های حسگر زیر آب: بکارگیری رویکرد یادگیری

¹ Generative Adversarial Neural

مداوم گره‌ها، به پروتکل‌های مسیریابی متفاوتی نسبت به شبکه‌های حسگر زمینی نیاز دارند. این شبکه‌ها با چالش‌های متعددی روبرو هستند؛ از جمله محدودیت‌های توان محاسباتی، ذخیره‌سازی و مصرف انرژی، که به دلیل شرایط محیطی پیچیده‌تر زیر آب، طراحی پروتکل‌های مسیریابی خاصی را می‌طلبد [11]. شبکه‌های زیر آب از امواج صوتی برای انتقال داده استفاده می‌کنند و با چالش‌هایی نظیر مصرف انرژی بالا، تاخیر زیاد و ظرفیت محدود مواجه‌اند. به همین دلیل، روش‌های مسیریابی سنتی برای شبکه‌های زمینی قابل استفاده نیستند و نیاز به رویکردهای نوین دارند [12]. در ادامه این بخش تحقیقات اخیر در زمینه مسیریابی در این شبکه‌ها به اختصار مرور می‌شوند. ما این رویکردها را در دو دسته بررسی کرده‌ایم: الگوریتم‌های مسیریابی بدون استفاده از یادگیری ماشین و الگوریتم‌های مسیریابی مبتنی بر یادگیری ماشین.

1.2. پروتکل‌های مسیریابی بدون استفاده از یادگیری

ماشین

استفاده از رویکردهای سنتی در مسیریابی شبکه‌های حسگر بی‌سیم زیر آب کماکان محبوب است. به عنوان نمونه مقاله [13] به بررسی رویکردهای مسیریابی جغرافیایی و فرصت‌محور برای شبکه‌های حسگر زیرآبی می‌پردازد. این پژوهش با در نظر گرفتن چالش‌های منحصربه‌فرد محیط‌های زیرآبی، یک الگوریتم مسیریابی جدید ارائه می‌دهد که با ترکیب اطلاعات جغرافیایی و مکانیزم‌های فرصت‌محور، قابلیت اطمینان و کارایی شبکه را بهبود می‌بخشد. روش پیشنهادی نه تنها بهره‌وری مصرف انرژی را افزایش می‌دهد، بلکه قابلیت تطبیق‌پذیری در برابر تغییرات محیطی و خرابی‌های احتمالی را نیز فراهم می‌کند. نتایج شبیه‌سازی نشان می‌دهد که این روش در مقایسه با الگوریتم‌های پیشین عملکرد بهتری از نظر تاخیر، مصرف انرژی و نرخ تحویل بسته دارد.

یکی از پرکاربردترین رویکردهای سنتی در شبکه‌های حسگر بی‌سیم زیر آب استفاده از مسیریابی مبتنی بر خوشه‌بندی است [14]. در این دسته از پروتکل‌ها، گره‌های حسگر به خوشه‌های

تقویتی برای مسیریابی در شبکه‌های حسگر بی‌سیم زیر آب که به عامل یادگیرنده اجازه می‌دهد با بهینه‌سازی پاداش تجمعی، مسیرهای هوشمندانه‌تری انتخاب شوند.

- استفاده از شبکه عمیق متخاصم زایشی (GAN) برای بهبود عملکرد رویکرد یادگیری تقویتی در فرآیند انتخاب مسیرها: استفاده از شبکه GAN برای تولید داده‌های مصنوعی و ترکیب آن با داده‌های واقعی به منظور بهبود فرآیند آموزش در مسیریابی در شبکه‌های حسگر زیر آب.
- مدل‌سازی مساله مسیریابی در شبکه‌های حسگر زیر آب با استفاده از فرآیند تصمیم‌گیری مارکوفی (MDP): بهره‌گیری از مدل تصمیم‌گیری مارکوف برای تعریف دقیق مساله و بهبود فرآیند تصمیم‌گیری در مسیریابی در محیط‌های تصادفی و پویای زیر آب.

- ارائه یک راه‌حل مبتنی بر الگوریتم یادگیری Q- برای حل مساله مسیریابی: ارائه الگوریتمی مبتنی بر یادگیری Q که به صورت پویا و بر اساس وضعیت جاری گره‌ها در زمان انتقال داده، مسیرهای بهینه را انتخاب می‌کند.

- مقایسه عملکرد با روش‌های یادگیری تقویتی سنتی: مقایسه عملی و شبیه‌سازی شده رویکرد پیشنهادی با رویکردهای پیشین که معیار مناسبی برای ارزیابی عملکرد رویکرد پیشنهادی است.

ادامه این مقاله از بخش‌های زیر تشکیل شده است. در فصل دوم پیشینه پژوهش به اختصار مرور می‌شود و در فصل سوم جزئیات رویکرد پیشنهادی به تفصیل بیان می‌گردد. در فصل چهارم نتایج به دست آمده از شبیه‌سازی ارائه شده و در نهایت فصل پنجم جمع‌بندی و کارهای آتی را ارائه می‌دهد.

2. پیشینه پژوهش

شبکه‌های حسگر بی‌سیم زیر آب به دلیل ویژگی‌های خاص محیطی و محدودیت‌های فنی مانند ساختار پویا و جابجایی

الگوریتم‌ها با تقلید از فرآیندهای طبیعی انتخاب طبیعی و بقای اصلح، به حل مسائل پیچیده و چندمنظوره مسیریابی پرداخته و توانایی بهینه‌سازی مسیرها را در شرایط مختلف دارند. در این روش، هر مسیر به عنوان یک کروموزوم در نظر گرفته می‌شود و به آنها نمره‌ای به نام تابع شایستگی اختصاص داده می‌شود که نشان‌دهنده کیفیت آن مسیر است. این تابع بر اساس معیارهای مختلفی مانند مصرف انرژی، زمان انتقال و تعداد گره‌های واسط محاسبه می‌شود. سپس با استفاده از تکنیک‌های انتخاب، تقاطع و جهش، نسل‌های جدیدی از کروموزوم‌ها تولید می‌شود که احتمالاً بهبود یافته و به سمت بهینه‌سازی حرکت می‌کنند. این فرآیند تکراری تا زمانی ادامه می‌یابد که یک راه‌حل قابل قبول یا بهینه به دست آید. الگوریتم‌ها می‌توانند زمان انتقال داده و مصرف انرژی را به طور چشمگیری کاهش دهند و در عین حال کارایی شبکه را افزایش دهند. از سوی دیگر، این الگوریتم‌ها به دلیل نیاز به محاسبات پیچیده و زمانبر، ممکن است در برخی سناریوهای واقعی دچار چالش‌هایی شوند.

استفاده از منطق فازی در مسیریابی شبکه‌های حسگر زیر آب به دلیل پیچیدگی‌های محیط و متغیرهای متعدد بسیار مفید است [20]. این روش با توانایی خود در مدیریت عدم قطعیت‌ها و پردازش اطلاعات ناقص، به تصمیم‌گیری‌های بهینه در انتخاب مسیر کمک می‌کند. با اعمال قواعد فازی، می‌توان به طور همزمان چندین معیار مانند مصرف انرژی، تاخیر و کیفیت سیگنال را مدنظر قرار داد و مسیرهای موثرتری را انتخاب کرد. علاوه بر این، منطق فازی می‌تواند به گره‌ها این امکان را بدهد که با توجه به وضعیت لحظه‌ای شبکه و شرایط محیطی، تصمیمات بهتری اتخاذ کنند. این قابلیت انعطاف‌پذیری به ویژه در شرایطی که داده‌های حسگر ممکن است نادرست یا ناقص باشند، ارزشمند است. با استفاده از منطق فازی، مسیریابی می‌تواند به طور همزمان بهینه‌سازی چندین هدف را دنبال کند و انعطاف بیشتری نسبت به رویکردهای سنتی داشته باشد.

در مقاله [21]، یک پروتکل مسیریابی جدید مبتنی بر فشار برای شبکه‌های حسگر بی‌سیم زیرآبی ارائه شده است. این پروتکل با هدف افزایش قابلیت اطمینان و بهبود بهره‌وری انرژی طراحی

جداگانه تقسیم می‌شوند تا بهره‌وری انرژی افزایش یابد. هر خوشه دارای یک سرخوشه است که وظیفه جمع‌آوری داده‌ها از اعضای خوشه و ارسال آنها به ایستگاه پایه یا گره سینک را برعهده دارد. خوشه‌بندی، با تقسیم منطقه به خوشه‌های پویا، باعث کاهش مصرف انرژی می‌شود. با این حال، سرخوشه‌ها به دلیل مصرف انرژی بالا نیاز به انتخاب هوشمندانه دارند تا تعادل مصرف انرژی در شبکه حفظ شود و طول عمر شبکه افزایش یابد [15]. برای مثال، در مرجع [16]، با استفاده از قدرت سیگنال برای انتخاب سرخوشه، پروتکلی ارائه شده است که به صورت چرخشی سرخوشه‌ها را انتخاب می‌کند. این روش می‌تواند طول عمر شبکه را افزایش دهد، اما از تعادل انرژی بین گره‌ها بهره‌مند نبود. در پژوهشی دیگر [17]، الگوریتمی ارائه شده است که سرخوشه‌ها را بر اساس انرژی باقیمانده و ارتباطات گره‌ها انتخاب می‌کردند که نتیجه آن بهبود اطمینان و بهره‌وری انرژی بود؛ با این حال، این روش با چالش‌هایی همچون توان عملیاتی کم و تاخیر مواجه است.

یکی دیگر از رویکردها، استفاده از ایده کلونی مورچه‌ها در رویکرد مسیریابی است [18]. در این روش از رفتار مورچه‌ها برای مسیریابی تقلید می‌شود و مسیرهایی که بیشترین بازدید را داشته‌اند، انتخاب می‌شوند. در این روش مسیرهایی که بیشتر مورد استفاده قرار می‌گیرند، تقویت می‌شوند و به تدریج به مسیرهای بهینه تبدیل می‌شوند. این رویکرد دارای مزایای زیادی است که آن را برای حل مسائل مسیریابی در شبکه‌های حسگر بی‌سیم جذاب می‌سازد. یکی از این مزایا، توانایی این روش در انطباق با تغییرات دینامیک محیط است. هنگامی که شرایط شبکه، مانند ناپایداری گره‌ها یا تغییرات توپولوژی، تغییر می‌کند، الگوریتم‌های کلونی مورچه‌ها می‌توانند به سرعت مسیره‌های جدیدی را شناسایی و بهبود بخشند. این سازگاری موجب می‌شود که شبکه بتواند به طور موثر و بدون نیاز به اطلاعات اولیه دقیق، عملکرد خود را بهینه‌سازی کند.

از سوی دیگر از الگوریتم ژنتیک نیز برای این منظور استفاده شده است [19]. در این روش با استفاده از انتخاب طبیعی و تابع شایستگی برای بهینه‌سازی مسیرها استفاده می‌شود. این

شده و از اطلاعات فشار حسگرها برای انتخاب مسیرهای بهینه و کاهش مصرف انرژی استفاده می‌کند. نتایج ارزیابی نشان می‌دهد که پروتکل ارائه شده در مقایسه با روش‌های موجود، از نظر مصرف انرژی، نرخ تحویل داده و طول عمر شبکه عملکرد بهتری دارد.

2.2. پروتکل‌های مسیریابی مبتنی بر یادگیری ماشین

امروزه از رویکردهای مبتنی بر یادگیری ماشین برای مسیریابی در شبکه‌های حسگر زیر آب نیز استفاده می‌شوند [22]. در مرجع [23]، یک پروتکل مسیریابی تطبیقی برای شبکه‌های حسگر آکوستیک زیرآبی ارائه شده که مبتنی بر شبکه‌های عمیق Q است. این پروتکل با هدف بهینه‌سازی مصرف انرژی و کاهش تاخیر طراحی شده است و از یادگیری عمیق برای اتخاذ تصمیمات هوشمند در انتخاب مسیرها استفاده می‌کند. روش پیشنهادی با تحلیل شرایط محیطی و ویژگی‌های شبکه، مسیرهایی را انتخاب می‌کند که مصرف انرژی را کاهش داده و تاخیر در ارسال داده‌ها را به حداقل برساند. نتایج تجربی نشان می‌دهد که این پروتکل در مقایسه با سایر روش‌ها، عملکرد بهتری از نظر طول عمر شبکه و بهره‌وری انرژی دارد.

از سوی دیگر، شبکه‌های عصبی توانایی تشخیص الگوهای پیچیده و غیرخطی را دارند و می‌توانند به طور موثری برای حل مسائل چندمعیاره در مسیریابی استفاده شوند. به ویژه در محیط‌های زیر آب که شرایط متغیر و چالش‌های خاصی نظیر تداخل سیگنال و محدودیت‌های انرژی وجود دارد، این شبکه‌ها می‌توانند به ارائه راهکارهای بهینه کمک کنند. با این حال، استفاده از شبکه‌های عصبی در مسیریابی به منابع محاسباتی بالایی نیاز دارد [24]. به علاوه، انتخاب ساختار مناسب شبکه و تنظیم پارامترها برای بهینه‌سازی عملکرد، چالش‌هایی هستند که محققان باید در نظر بگیرند. این الگوریتم‌ها می‌توانند با یادگیری از داده‌های تاریخی، عملکرد خود را در شرایط مختلف بهبود بخشند و به عنوان یک ابزار قدرتمند در طراحی پروتکل‌های مسیریابی جدید در شبکه‌های حسگر زیر آب مورد استفاده قرار گیرند.

یکی دیگر از رویکردها برای مسیریابی در این نوع از شبکه‌ها، استفاده از الگوریتم‌های مبتنی بر یادگیری تقویتی است [25]. این الگوریتم‌ها به گره‌ها اجازه می‌دهند تا از طریق آزمون و خطا بهترین مسیرها را کشف کنند و به تدریج عملکرد شبکه را بهینه سازند. در این روش‌ها، گره‌ها با ارسال داده‌ها از مسیرهای تصادفی و دریافت پاداش، مانند تاخیر یا نرخ خطا، بهترین مسیرها را شناسایی می‌کنند. جدول (1) تناظر مولفه‌های یادگیری تقویتی و مسیریابی در شبکه‌های حسگر بی سیم زیر آب را نشان می‌دهد.

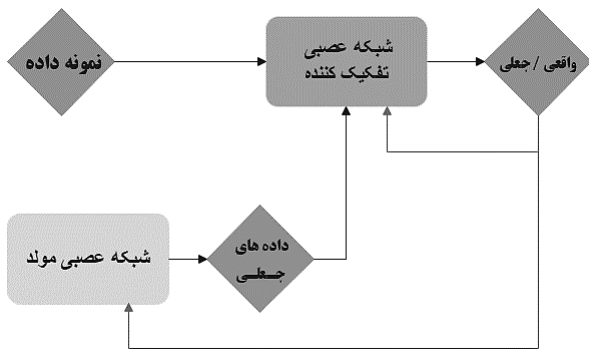
جدول (1): مولفه‌های یادگیری تقویتی در مسیریابی شبکه‌های حسگر

عامل یادگیر	حسگر بی سیم
عمل	انتخاب گره بعدی جهت تحویل بسته داده
وضعیت	وضعیت انرژی و موقعیت و ... گره حسگر بی سیم
پاداش	بازخورد نسبت به حسگر انتخاب شده برای تحویل بسته

یکی از پرکاربردترین الگوریتم‌های یادگیری تقویتی در این حوزه، الگوریتم یادگیری Q- است. هر گره در این الگوریتم، جدولی به نام جدول Q را نگه می‌دارد که ارزش هر مسیر ممکن به مقصد را ثبت می‌کند. با ارسال داده‌ها و دریافت پاداش، گره جدول خود را به‌روزرسانی می‌کند و در نهایت بهترین مسیر را می‌یابد. این الگوریتم، به ویژه در شرایطی که گره‌ها اطلاعات کامل از وضعیت شبکه ندارند، بسیار کارآمد است [25].

در این راستا، در مرجع [26]، الگوریتمی مبتنی بر یادگیری Q- ارائه دادند که با در نظر گرفتن پارامترهایی مانند انرژی باقیمانده و تاخیر، گره بعدی را انتخاب می‌کرد. نتیجه این پژوهش کاهش مصرف انرژی و تاخیر بود، هرچند گاهی اوقات گره‌های غیربهینه نیز انتخاب می‌شدند. راهکارهای مبتنی بر یادگیری تقویتی توسعه دادند که به گره‌ها اجازه می‌داد به طور فرصت‌طلبانه بسته‌ها را ارسال کنند. این تصمیم‌گیری بر اساس شرایط لحظه‌ای کانال و موقعیت گره‌ها انجام می‌شد و نتایج نشان داد که مصرف انرژی به طور چشمگیری کاهش یافته و تاخیر شبکه بهبود پیدا کرده است.

توسط تشخیص‌دهنده به عنوان داده واقعی شناسایی شوند. نحوه عملکرد GAN به این صورت است که مولد سعی می‌کند نمونه‌هایی شبیه به داده‌های واقعی تولید کند، در حالی که تشخیص‌دهنده وظیفه دارد که بین داده‌های واقعی و داده‌های تولید شده توسط مولد تفاوت قائل شود. در طول فرآیند آموزش، مولد تلاش می‌کند تا به مرور زمان توانایی خود را در فریب دادن تشخیص‌دهنده افزایش دهد و تشخیص‌دهنده نیز در مقابل بهبود می‌یابد تا تفاوت بین داده‌های واقعی و داده‌های تولیدی را شناسایی کند. این رقابت باعث بهبود کیفیت داده‌های تولیدی می‌شود و در نهایت مولد قادر به تولید نمونه‌های بسیار واقعی از داده‌ها می‌شود. نحوه عملکرد GAN به طور خلاصه در شکل (1) نشان داده شده است.



شکل (1): خلاصه عملکرد شبکه‌های متخاصم زایشی

با توجه به ثابت بودن موقعیت حسگرها و مکانیزم مشخص برای انتخاب مسیرهای بهینه، احتمال وقوع شرایطی وجود دارد که مسیرهای انتخاب شده مشابه یا حتی تکراری باشند. این موضوع به ویژه در شبکه‌هایی که حسگرها از مسیرهای پیشنهادی الگوبرداری می‌کنند، قابل مشاهده است. با این حال، در الگوریتم پیشنهادی ما که مبتنی بر یادگیری Q طراحی شده، کیفیت مسیرها به صورت دینامیک و بر اساس معیارهای لحظه‌ای ارزیابی می‌شود. بنابراین، حتی در شرایطی که مسیرهای مشابه به عنوان بهینه پیشنهاد شوند، این امر به معنای یک مشکل اساسی در ساختار الگوریتم نیست، زیرا سازوکار یادگیری Q به گونه‌ای است که قابلیت انطباق با شرایط متغیر شبکه را دارد. یکی از ویژگی‌های کلیدی الگوریتم یادگیری Q این است که بر

ترکیب الگوریتم‌های یادگیری تقویتی با نظریه بازی نیز یکی از نوآوری‌های اخیر در حوزه مسیریابی در شبکه‌های حسگر بی‌سیم زیر آب است [27]. این رویکرد به گره‌ها اجازه می‌دهد تا با استفاده از مدل‌سازی نظریه بازی به عنوان یک بازی چندنفره، مسیریابی توزیع شده و کارآمدی را انجام دهند. به ویژه در شرایطی که اطلاعات کامل شبکه در دسترس نیست، این ترکیب می‌تواند تصمیم‌گیری‌های هوشمندانه‌ای در مسیریابی ایجاد کند.

3.2. جمع‌بندی

روش‌های مختلف مسیریابی در شبکه‌های حسگر بی‌سیم زیر آب هر کدام دارای مزایا و معایبی هستند. پروتکل‌های مبتنی بر خوشه‌بندی انرژی را بهینه‌تر مدیریت می‌کنند، اما نیازمند انتخاب هوشمندانه سرخوشه‌ها هستند. از سوی دیگر، روش‌های مبتنی بر یادگیری تقویتی و نظریه بازی، با یادگیری از تجربه و آزمون و خطا، مسیریابی توزیع شده و پویا را فراهم می‌کنند، هرچند پیاده‌سازی آنها به دلیل پیچیدگی‌های محیطی و محاسباتی چالش‌برانگیز است. در نهایت، انتخاب روش مناسب مسیریابی باید بر اساس نیازها و محدودیت‌های خاص هر شبکه و محیط زیر آب انجام شود.

3. رویکرد پیشنهادی

هدف اصلی رویکرد پیشنهادی در این مقاله، بکارگیری شبکه‌های متخاصم زایشی در فرآیند کشف مسیر الگوریتم مسیریابی مبتنی بر یادگیری Q- در شبکه‌های حسگر بی‌سیم زیر آب است. تحقیقات پیشین نشان داده‌اند که شبکه‌های متخاصم زایشی در کاربردهای مختلف، از جمله ارائه مسیرهای بین دو نقطه با استفاده از تصاویر هوایی، بهینه‌سازی تخصیص منابع در شبکه‌های بی‌سیم و تقویت عملکرد سیستم‌های تشخیص نفوذ، بهبودهای چشمگیری ایجاد می‌کنند.

ساختار اصلی GAN شامل دو شبکه عصبی جداگانه به نام‌های مولد و تشخیص‌دهنده است که به صورت رقابتی (متخاصم) در برابر یکدیگر آموزش می‌بینند. هدف اصلی این شبکه‌ها تولید داده‌هایی است که به قدری شبیه به داده‌های واقعی باشند که

شبکه‌های حسگر بی‌سیم زیر آب از اهمیت بالایی برخوردارند و به حفظ طول عمر شبکه و ارتباط موثر کمک می‌کنند:

- مقدار و سطح انرژی گره
 - فاصله بین دو گره (تراکم) و فاصله نسبت به گره سینک
- فرآیند تصمیم مارکوف در رویکرد پیشنهادی به صورت زیر تعریف می‌شود:
- k : وضعیت گره‌های شبکه از جمله موقعیت و سطح انرژی که بسته از آنجا ارسال می‌گردد (مبدأ).
- A : مسیر و گره‌ای که برای تحویل بسته به گره پایه انتخاب می‌شود.
- R : پاداش اختصاص یافته به گره مبدأ پس از انتقال بسته از گره به گره دیگر.

تابع پاداش $R(s, a)$ به صورت زیر تعریف می‌شود:

$$R(s, a) = R(cur, nbr) - \frac{d(cur, nbr)}{E(cbr)} + E(nbr) \quad (1)$$

که در آن $d(cur, nbr)$ - اختلاف فاصله گره فعلی تا گره بعدی است، $E(nbr)$ انرژی گره بعدی، $E(cbr)$ انرژی گره فعلی، $R(cur, nbr)$ مقدار پاداش جابجایی بسته از وضعیت فعلی به وضعیت بعدی است. شایان ذکر است کسر $\frac{d(cur, nbr)}{E(cbr)}$ در واقع مقدار فاصله حسگر فعلی تا همسایه‌ای که بسته به آن تحویل داده می‌شود بر انرژی گره فعلی است و این کسر به صورت منفی در معادله قرار گرفته است و بزرگ‌تر بودن این عبارت باعث کاهش پاداش خواهد شد و اثر منفی روی مسیریابی خواهد داشت.

انتقال بسته از یک گره به گره دیگر زمانی موثر است که در تحویل بسته به گره انتخابی، هم فاصله بین گره‌ها کم باشد و هم گره مقصد دارای سطح انرژی مناسبی باشد و پیش از این نیز انتخاب نشده باشد. زیرا فاصله زیاد منجر به مصرف انرژی بیشتر توسط گره فعلی می‌شود. افزایش سطح انرژی گره کاندید (گره بعدی یا همسایه) به عنوان یک پاداش، به طور غیرمستقیم می‌تواند از تحویل مکرر بسته به یک گره خاص و در نتیجه

اساس سیستم پاداش‌دهی عمل می‌کند. اگر استفاده مکرر از مسیرهای تکراری منجر به کاهش پاداش شود - برای مثال، به دلیل افزایش مصرف انرژی در گره‌های مشارکت کننده، کاهش عمر باتری یا تراکم ترافیکی - الگوریتم این کاهش پاداش را شناسایی کرده و به طور خودکار به جستجوی مسیرهای جایگزین می‌پردازد. این فرآیند تطبیقی به الگوریتم اجازه می‌دهد تا نه تنها از مسیرهای کم‌بازده و تکراری اجتناب کند، بلکه بهینه‌ترین مسیرها را با توجه به وضعیت کنونی شبکه شناسایی نماید. به عبارت دیگر، سیستم به طور مداوم در حال یادگیری از تجربیات گذشته است و قادر است تصمیمات بهتری برای آینده بگیرد. این فرآیند تطبیقی به ویژه در شبکه‌های حسگر بی‌سیم که با محدودیت‌های منابع انرژی، تراکم داده و نوسانات محیطی مواجه هستند، اهمیت بالایی دارد. اگرچه مسیرهای مشابه ممکن است در کوتاه مدت به عنوان بهینه شناسایی شوند، اما الگوریتم پیشنهادی ما به دلیل طراحی پویا و انعطاف‌پذیر خود، این قابلیت را دارد که در بلند مدت مسیرهای کارآمدتری را پیدا کرده و استفاده از منابع را بهینه کند. این ویژگی همچنین تضمین می‌کند که شبکه در برابر تغییرات غیرمنتظره مانند خرابی گره‌ها یا افزایش بار ترافیکی مقاوم باقی می‌ماند.

در نهایت، این نکته حائز اهمیت است که تکرار مسیرها تنها زمانی به چالشی واقعی تبدیل می‌شود که بهره‌وری شبکه به شکل قابل توجهی تحت تاثیر قرار گیرد. در این حالت، الگوریتم یادگیری-Q با اعمال تغییرات در تصمیم‌گیری‌های خود و ارائه مسیرهای جدید و کارآمدتر، این مشکل را مدیریت می‌کند. چنین قابلیت‌هایی باعث شده که الگوریتم پیشنهادی نه تنها به عنوان راهکاری برای مسیریابی بهینه، بلکه به عنوان سیستمی هوشمند و خودتنظیم برای مدیریت منابع در شبکه‌های حسگر بی‌سیم مطرح شود. در ادامه مراحل رویکرد مسیریابی پیشنهادی برای شبکه‌های حسگر بی‌سیم زیر آب تشریح شده‌اند.

1.3. ارزیابی بسته‌های ارسالی و مسیرهای انتخابی

در روش پیشنهادی، دو معیار کلیدی در تعریف الگوریتم مسیریابی در نظر گرفته شده است، زیرا این دو معیار در

با تعداد گام تا گره سینک. در عمل الگوریتم شبکه متخاصم زایشی بازخورد ارزش مسیری را که ارائه کرده است، دریافت می‌کند تا در مراحل بعدی مسیرهای مشابه را تولید کند. همچنین هر گره می‌آموزد که کدام گره‌ها در مسیر می‌توانند مفید باشند تا از بین مسیرهای ارائه شده، انتخاب هوشمندانه‌تری انجام دهد. شبکه متخاصم زایشی تلاش می‌کند با توجه به تجربیات خود، مسیرهای بهتری تولید کند.

در ابتدای کار، پس از استقرار گره‌ها، گره سینک یک بسته حاوی مشخصات خود، از جمله مختصاتش را توزیع می‌کند. هر گره با دریافت این پیام، اطلاعات مربوط به خود را درون بسته قرار داده و آن را مجدد برادکست می‌کند. در این مرحله، تمام گره‌ها مختصات گره سینک و همسایگان در دسترس خود را دریافت می‌کنند. مسیر به دست آمده از شبکه متخاصم زایشی در سرآیند بسته ارسالی از سوی گره درخواست‌کننده مسیر قرار می‌گیرد تا با جابجایی بسته، گره بعدی بتواند سرآیند را استخراج کرده و دریابد که بسته را به کدام گره تحویل دهد. هر گره حسگر موظف است تا تابع ارزش و تابع پاداش خود را تا گره بعدی محاسبه کند. پس از طی شدن این فرآیند، پیامی مبنی بر صحت انتقال و ارتباط به مبدا از مسیر طی شده بازمی‌گردد. این بسته می‌تواند حاوی اطلاعات لازم برای تخمین ارزش مسیر تولید شده توسط هر گره در چرخه‌های بعدی باشد. برای تکرار چرخه مسیریابی و استفاده از شبکه متخاصم زایشی و مسیرهای تولید شده، همواره مسیرها بر اساس دانش فعلی گره و تجربیات پیشین انتخاب می‌شوند، به گونه‌ای که هر مسیری که دارای گره‌های با ارزش‌تری باشد، انتخاب می‌شود.

2.3. بررسی ارسال و انتقال بسته‌ها

در رویکرد پیشنهادی ما در محیط شبکه حسگر بی‌سیم زیر آب، قبل از شروع فرآیند و در مرحله شناسایی، تمامی گره‌های حسگر همسایگان خود را شناسایی کرده و موقعیت خود را در شبکه تثبیت می‌کنند. پس از این مرحله، گره‌های متخاصم مستقر در محیط اطلاعات مربوط به گراف همسایگی حسگرها را دریافت می‌کنند. لازم به ذکر است که تمامی حسگرها در

انتخاب مکرر آن توسط شبکه متخاصم زایشی جلوگیری کند (بهینه‌سازی محلی). در روش پیشنهادی، مقدار ارزش حالت - عمل به صورت زیر محاسبه می‌شود:

$$Q^* = (1 - \alpha) old(cur, nbr) + \alpha(R(cur, nbr) + Q(nbr)) \quad (2)$$

$$Q = R(vur, nbr) + Q(nbr)$$

که در آن α ضریب تاثیر ارزش قبلی گره (یادگیری های قبلی) و $R(cur, nbr)$ مقدار پاداش جا به جایی بسته از وضعیت فعلی به وضعیت بعدی است. در اینجا Q مقدار ارزش حالت - عمل به ازای یک جابه‌جایی خواهد بود و Q^* مقدار به‌روزرسانی آن، به عبارت دیگر Q^* مشخص می‌سازد در قرار دادن ارزش برای یک (حالت - عمل) چقدر به دانش قبلی اهمیت دهیم و چه میزان به دانش و یا همان ارزش محاسبه شده جدید.

در بخشی از فرمول محاسبه ارزش حالت - عمل، مقدار ارزش محض گره $Q(s)$ مشخص می‌شود که از رابطه زیر به دست می‌آید:

$$Q(s) = \frac{E(cur)}{N} \quad (3)$$

که در آن $E(cur)$ انرژی گره جاری و N برابر با تعداد گام فاصله گره جاری تا گره سینک است. این مقدار نشان‌دهنده این است که هر گره‌ای که به گره سینک نزدیک‌تر باشد، می‌تواند ارزش ویژه‌ای داشته باشد، زیرا ارسال بسته به این گره‌ها به صورت دوره‌ای می‌تواند از طولانی شدن مسیر و افزایش تعداد گام‌های نزدیک به هم در مسیرهای ارائه شده توسط شبکه متخاصم زایشی جلوگیری کند. پس از گذر از مسیر و تحویل بسته از گره‌ای به گره دیگر، ارزش کلی مسیر با تقسیم مجموع ارزش‌های گره‌ها به تعداد گره‌های مشارکت‌کننده در مسیر محاسبه می‌شود و به گره‌ها اعلام می‌گردد. این ارزش به شبکه متخاصم زایشی ارائه شده و از طریق رابطه زیر محاسبه می‌شود:

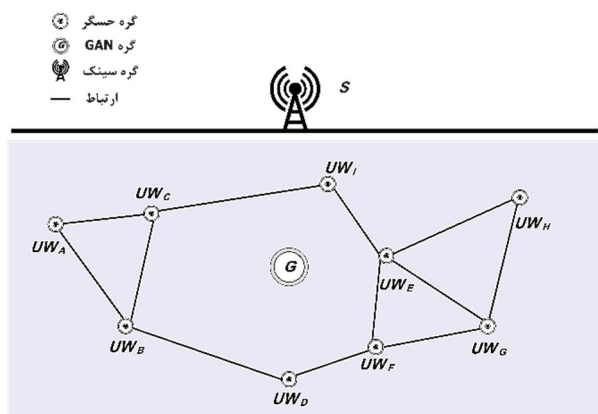
$$Q(Total) = Q \frac{(Hop 1 \dots Hop n - 1)}{N} \quad (4)$$

که در آن $Q(hop 1, \dots, hop n)$ برابر است با مقدار مجموع تمام ارزش‌های گره‌های حسگر در طول مسیر و N برابر است

5. بازخورد به شبکه متخاصم و گره‌های شرکت کننده در مسیر ارسال می‌گردد.

تفاوت میان این دو چرخه در این است که در چرخه اول، گره هیچ دانشی از مسیرها ندارد، اما در چرخه‌های بعدی، دانش به تدریج کسب می‌شود. یک مثال از اجرای رویکرد پیشنهادی در شکل (2) نشان داده شده است که در آن گره‌ها به انواع زیر تقسیم می‌شوند:

- گره‌های حسگر شبکه
- گره ایستگاه پایه
- گره متخاصم



شکل (2): نمونه شبکه حسگر بی سیم زیر آب

جهت روشن شدن رویکرد پیشنهادی، مثال زیر را در نظر بگیرید. گره UW_D درخواست ارسال یک بسته دارد. بنابراین گره G مسیرهای پیشنهادی را به UW_D ارسال می‌کند. حال گره UW_D یک مسیر را برای اولین بار به صورت تصادفی انتخاب می‌کند (به عنوان مثال مسیر تصادفی $S-UW_I-UW_E-UW_F-UW_D$). در ادامه مسیری که در شکل (3) نشان داده شده است، پیمایش شده و مقادیر زیر محاسبه می‌شود:

$$Qvalue_Total = Qvalue(UW_D - UW_F) + Qvalue(UW_F - UW_E) + Qvalue(UW_E - UW_I) + Qvalue(UW_I - S) / HopCount \quad (5)$$

در نهایت نتایج به دست آمده باید برای همه گره‌ها ارسال شده

موقعیت خود ثابت هستند و حرکات قابل توجهی که بر ارسال و دریافت پیام و تغییر مسیر تاثیرگذار باشد، ندارند.

شبکه متخاصم با در اختیار داشتن اطلاعات گراف همسایگی تمامی حسگرها، قادر است مسیرهای واقعی موجود را ارائه دهد. این ویژگی به الگوریتم کمک می‌کند تا زودتر به مسیرهای بهینه دست یابد و از پیمایش مسیرهای غیرواقعی اجتناب کند. در فرآیند مسیریابی گره‌های حسگر، دو نوع عملکرد وجود دارد که به آنها چرخه اول و چرخه دوم می‌گوییم.

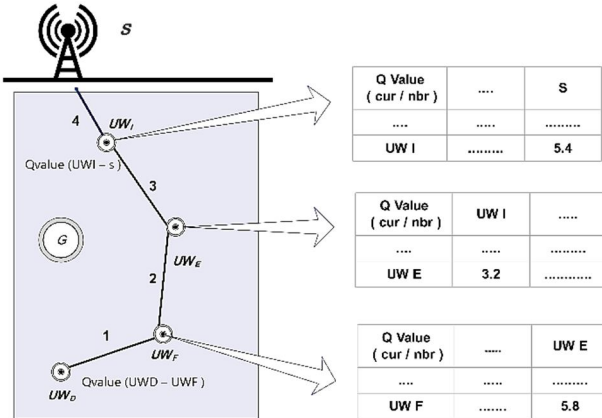
در مسیریابی (چرخه اول):

1. گره حسگر در چرخه اول از شبکه متخاصم درخواست ارسال بسته می‌کند.
2. شبکه متخاصم مجموعه‌ای از مسیرها را در اختیار گره حسگر قرار می‌دهد.
3. گره حسگر به طور تصادفی یکی از مسیرها را انتخاب می‌کند.
4. مسیر طی شده و ارزش انتقال بسته برای هر پرش حسگر و پاداش محاسبه می‌شود.
5. بازخورد به GAN و گره‌های شرکت کننده در مسیر ارسال می‌گردد.

در مسیریابی (چرخه دوم):

1. گره حسگر از شبکه متخاصم درخواست ارسال بسته می‌کند.
2. شبکه متخاصم مجموعه‌ای از مسیرها را در اختیار گره حسگر قرار می‌دهد.
3. اگر گره حسگر پیش از این سابقه ارسال بسته را داشته باشد، با توجه به دانش قبلی خود یکی از مسیرها را انتخاب می‌کند (محاسبه ارزش مسیر بر اساس اطلاعات قبلی).
4. مسیر طی شده و ارزش انتقال بسته برای هر پرش حسگر و پاداش محاسبه می‌شود.

هر یک از گره‌های حسگر پس از دریافت نتیجه و ارزش انتقال بسته از گره به گره دیگر، جدول مقدار Q را مانند شکل (5) تکمیل می‌کنند تا در چرخه ارسال بعدی بتوانند از مسیرهایی که شبکه متخصص در اختیار آنها قرار می‌دهد مسیرهایی با ارزش بیشتر را انتخاب کنند.




شکل (5): تکمیل جدول یادگیری برای هر گره حسگر

شایان یادآوری است در الگوریتم‌هایی که بر پایه یادگیری تقویتی بنا شده‌اند، دو اصل بهره‌وری و اکتشاف مطرح است. در روش‌های مبتنی بر یادگیری تقویتی، عامل با حضور در محیط و تجربه حالات جدید می‌تواند یادگیری را در طی فرآیند پیمایش محیط انجام دهد. از سوی دیگر، عامل می‌تواند به اطلاعات فعلی خود اتکا کند یا فضای جدیدی از حالات را تجربه کرده و دانش خود را با اطلاعات تازه به‌روزرسانی کند.

در راهکار پیشنهادی، از میان مسیرهای ارائه شده توسط گره GAN، گره حسگر مسیرهایی را انتخاب می‌کند که ارزش بالاتری را برای او به ارمغان می‌آورد و بدین ترتیب بهره‌وری شبکه را افزایش می‌دهد. در این میان، گره حسگر ممکن است به طور تصادفی با حالت‌هایی مواجه شود که تجربه‌ای از آنها ندارد و برای اولین بار با آنها روبه‌رو می‌شود که این حالت به عنوان یک فرآیند اکتشافی در نظر گرفته می‌شود.

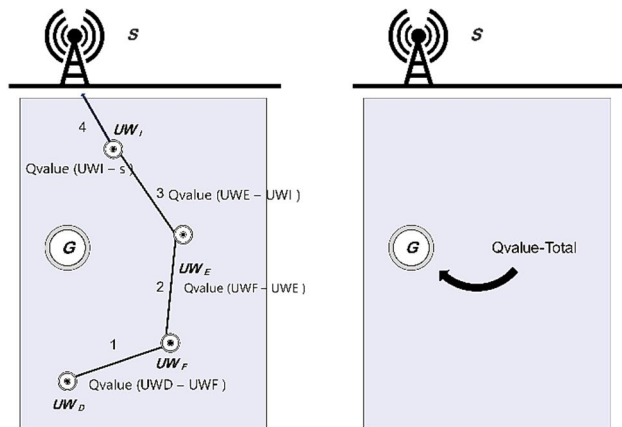
الگوریتم GAN که در شبکه حسگر برای کشف مسیر ارائه شده است به صورت زیر تعریف می‌شود. شبکه تولیدکننده به ترتیب از 128، 256 و 30 لایه و شبکه تشخیص‌دهنده از لایه‌هایی به تعداد 128، 256 و 1 تشکیل می‌شود. ورودی داده‌ها، که شامل

تا در حافظه خود ذخیره کنند و در نهایت مقدار ارزش تجمیعی مسیر را در اختیار گره GAN قرار دهند.



شکل (3): نحوه پیمایش مسیر

در ادامه و در چرخه‌های بعدی، اگر یک گره یک بسته برای ارسال داشته باشد، شبکه متخصص با بازخوردی که از مسیرهای تولیدی در چرخه‌های قبلی گرفته سعی خواهد کرد تا مسیر بهینه‌تری را تولید کند. سپس لیست مسیرها در اختیار حسگر قرار می‌گیرد و حسگر با توجه به یادگیری قبلی خود تخمین می‌زند که کدام مسیر ارزش بالاتری دارد (روند بازگرداندن نتیجه مسیریابی و ارزش‌ها در شکل (4) نمایش داده شده است)، یعنی از میان مسیرهای ارائه شده، انتقال به سمت گره‌ای صورت می‌گیرد که ارزش بهتری داشته باشد. در ادامه گره مسیر را انتخاب کرده و بسته به سمت مقصد خود ارسال می‌شود. همچنین همانند چرخه اول مقادیر مربوطه محاسبه شده و در اختیار حسگرها و گره GAN قرار می‌گیرد.



شکل (4): ارائه بازخورد به گره‌ها

حسگر بی سیم مراحل و تنظیمات زیر در نظر گرفته شده‌اند:

مرحله 1 (ایجاد داده‌های تصادفی مسیر): با توجه به نیاز به داده‌های آموزشی برای آموزش مدل، ابتدا داده‌های آموزشی متناسب با شرایط مساله تولید می‌شوند. برای این منظور، 100 ماتریس مسیر با تعداد گره‌های متغیر بین 2 تا 30 ایجاد می‌شود. هر یک از این مسیرها دارای ویژگی‌هایی هستند که برای حل مساله ضروری‌اند، از جمله طول مسیر، کیفیت لینک بین 0 تا 1، مصرف انرژی در هر گره (با ضریبی از 10) و مقدار پاداش که بین 0 تا 0/1 قرار دارد.

مرحله 2 (بارگذاری مجموعه داده): برای اجرای مدل، مجموعه‌ای از داده‌های مسیرها نیاز است. در این مرحله، داده‌های مربوط به مسیرها در شبکه حسگر بی سیم بارگذاری می‌شوند. این مجموعه داده شامل اطلاعاتی مانند مسیر، طول مسیر، کیفیت لینک، میزان مصرف انرژی و مقدار پاداش هر مسیر است.

مرحله 3 (تعریف معماری شبکه متخاصم زایشی برای تولید مسیر): برای ساخت مدل شبکه متخاصم زایشی، باید شبکه‌های تولیدکننده و تشخیص دهنده ایجاد شوند. شبکه تولیدکننده دارای سه لایه به ترتیب 128، 256 و 30 واحد است و هر لایه 64 نرون دارد. شبکه تشخیص دهنده نیز شامل سه لایه با 128، 256 و 1 واحد است. تعداد نرون‌ها پس از آزمایش‌های مختلف برای دستیابی به بهترین عملکرد تعیین شده‌اند.

در لایه‌های میانی از تابع فعال‌ساز ReLU استفاده شده است که در یادگیری عمیق بسیار رایج است. این تابع مقادیر منفی را صفر و مقادیر مثبت را به همان شکل نگه می‌دارد. در آخرین لایه شبکه تولیدکننده از تابع فعال‌ساز Tanh استفاده شده است؛ زیرا این نوع شبکه‌ها به طور معمول خروجی‌های غیرخطی تولید می‌کنند و توابع فعال‌ساز غیرخطی برای این مرحله مناسب‌تر هستند. در شبکه تشخیص دهنده، از تابع فعال‌ساز Sigmoid در انتهای مدل استفاده می‌شود تا خروجی به شکل احتمالاتی باشد.

مرحله 4 (آموزش مدل شبکه متخاصم زایشی): در این مرحله، پس از تعریف اصطلاحات مربوط به آموزش، به آموزش مدل GAN با استفاده از داده‌های موجود در مجموعه داده‌ها

اطلاعات گره‌های مسیر است، در تولیدکننده پردازش می‌شود و پس از پردازش به شبکه تفکیک‌کننده تحویل داده می‌شود. سپس این داده‌ها بر اساس بازخوردهای دریافتی توسط الگوریتم یادگیری Q-ارزیابی می‌شوند. استفاده از شبکه‌های متخاصم زایشی در این روش پیشنهادی می‌تواند نتایج زیر را به دنبال داشته باشد:

- تولید مسیرهای متنوع: این روش می‌تواند مسیرهای بسیار متنوعی ایجاد کند که شانس یافتن مسیر بهینه را افزایش می‌دهد. به عنوان مثال، انتخاب تصادفی مسیر در اولین پیمایش، وابستگی مسیریابی به یک گره خاص را از بین می‌برد.
- کشف مسیرهای ناشناخته: این روش قادر است مسیرهایی را کشف کند که ممکن است با روش‌های سنتی مسیریابی قابل شناسایی نباشند. برای نمونه، با تغییر سطح انرژی گره‌ها، گاهی ممکن است بسته‌ها از مسیر کوتاه‌تر به یک مسیر طولانی‌تر جدید هدایت شوند که این تغییر می‌تواند به افزایش طول عمر شبکه کمک کند.
- انطباق با تغییرات شبکه: این روش می‌تواند خود را با تغییرات در توپولوژی شبکه و شرایط محیطی سازگار کند.

4. نتایج شبیه‌سازی

در این بخش جهت ارزیابی رویکرد پیشنهادی، آن را در کنار یک الگوریتم مسیریابی مبتنی بر یادگیری تقویتی [27] پیاده‌سازی کرده‌ایم تا بتوانیم کارایی و عملکرد رویکرد پیشنهادی را به خوبی ارزیابی کنیم. برای شبیه‌سازی از ابزار متلب نسخه 2024a و کتابخانه یادگیری عمیق استفاده کرده‌ایم. در این شبیه‌سازی از یک شبکه حسگر بی سیم با تعداد 50 گره در یک محیط با ابعاد 1000 در 1000 متر استفاده شده است و نتایج ارائه شده میانگین 25 بار اجرای هر آزمایش هستند.

1.1. جزئیات پیاده‌سازی رویکرد پیشنهادی

برای پیاده‌سازی دقیق رویکرد پیشنهادی و ایجاد یک مدل GAN برای تولید مسیر و یکپارچه‌سازی آن با یادگیری Q-در شبکه

انرژی در هر گره (با ضریب 10)، و مقدار پاداش (بین 0 تا 0/1) می‌باشد. در طول فرآیند شبیه‌سازی، گره‌های حسگر به صورت تصادفی داده‌هایی برای ارسال به سمت گره سینک تولید می‌کنند. نرخ متوسط تولید داده‌ها در طول فرآیند شبیه‌سازی بین 150 کیلو بیت بر ثانیه تا 500 کیلو بیت بر ثانیه تنظیم شده است. خلاصه پارامترهای استفاده شده در فرآیند شبیه‌سازی در جدول (2) آمده است.

جدول (2): خلاصه پارامترهای شبیه‌سازی

پارامتر	مقدار/توضیحات
تعداد گره‌ها	50
ابعاد محیط شبیه‌سازی	1000 × 1000 متر
تعداد تکرار آزمایش‌ها	25 بار
محدوده کیفیت لینک	بین 0 تا 1
مصرف انرژی در هر گره	ضریبی از 10
محدوده پاداش مسیره‌ها	بین 0 تا 0/1
انرژی اولیه هر گره	1/25 ژول
نرخ تولید داده	بین 150 کیلو بیت بر ثانیه تا 500 کیلو بیت بر ثانیه
عامل کاهش در یادگیری (γ)	0/9
نرخ یادگیری در یادگیری (α)	0/1
ابزار شبیه‌سازی	متلب نسخه 2024a و کتابخانه یادگیری عمیق

برای ارزیابی و بررسی عملکرد روش پیشنهادی، از معیارهای مختلفی استفاده شده است. در ادامه، ضمن معرفی این معیارها، روش پیشنهادی را با یکی از جدیدترین روش‌های موجود (یادگیری تقویتی) مقایسه می‌کنیم.

1.2.4. همگرایی

قبل از هر معیار دیگری، بررسی همگرایی روال یادگیری استفاده شده در رویکرد پیشنهادی در شکل (6) نشان داده شده است. در این شکل همگرایی بر اساس پاداش تجمعی محاسبه شده است. شایان ذکر است پاداش تجمعی معیاری رایج در یادگیری تقویتی است که مجموع پاداش‌های دریافت شده توسط عامل در تمام

می‌پردازیم. برای این منظور، یک تابع به نام trainGAN ایجاد کردیم که مدل را آموزش می‌دهد.

بهینه‌سازهای مختلفی برای اهداف متفاوت مانند طبقه‌بندی یا رگرسیون وجود دارند، اما برای داده‌های ما، بهینه‌ساز Adam نتایج بهتری ارائه داده است. همچنین، تابع زیان Cross-Entropy انتخاب شده است. این تابع باعث می‌شود که شبکه عصبی نه تنها خروجی‌ای نزدیک به خروجی واقعی تولید کند، بلکه با اطمینان بالا کلاس هدف را تشخیص دهد.

مرحله 5 (تولید مسیر): پس از آموزش شبکه تولیدکننده، تولید مسیرهای جدید آغاز می‌شود. این کار با استفاده از تولیدکننده آموزش دیده و تولید ورودی‌های تصادفی برای ایجاد مسیرهای جدید انجام می‌شود.

مرحله 6 (پیاده‌سازی یادگیری-Q برای مسیریابی): یادگیری-Q یک الگوریتم یادگیری تقویتی بدون نیاز به نمونه‌برداری است که ارزش هر عمل را در یک وضعیت خاص یاد می‌گیرد. این الگوریتم از چندتایی (S, A, α, γ) استفاده می‌کند، که در آن S مجموعه حالات، A مجموعه اعمال، α نرخ یادگیری و γ عامل کاهش است. سپس یک جدول Q ایجاد می‌شود و با استفاده از معادله بلمن، هنگام تعامل عامل با محیط (در اینجا مسیرهای تولید شده) به‌روزرسانی می‌گردد.

مرحله 7 (تکرار و ترکیب مسیرها): پس از تولید مجموعه‌ای از مسیرها توسط GAN، از یادگیری-Q استفاده می‌شود تا بهترین مسیر بر اساس معیارهای ارزیابی و پاداش انتخاب شود. در نهایت، عامل یاد می‌گیرد که کدام مسیرها را برای رسیدن به گره مقصد انتخاب کند و همزمان معیارهای ارزیابی را بهینه‌سازی نماید.

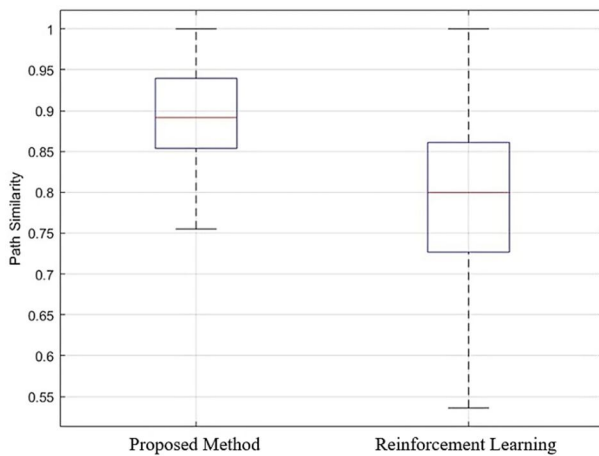
2.4. نتایج عددی

با توجه به اینکه برای آموزش و ارزیابی نتایج به داده‌های آزمایشی نیاز است، از مجموعه داده‌ای تصادفی که شامل 100 ماتریس مسیر با تعداد گره‌هایی بین 2 تا 30 است، استفاده شده است. هر یک از این مسیرها دارای ویژگی‌های مورد نیاز مساله است که شامل طول مسیر، کیفیت لینک (بین 0 تا 1)، مصرف

2.2.4. شباهت مسیر


معیار ارزیابی شباهت مسیر (Path Similarity) در واقع سطح شباهت بین مسیرهای تولید شده توسط یک الگوریتم و مسیرهای مرجع (یا واقعی) را بررسی می‌کند. از این معیار برای ارزیابی الگوریتم‌های مسیریابی در شبکه‌های حسگر بی‌سیم استفاده می‌شود و نشان می‌دهد که چه میزان مسیرهای پیشنهادی الگوریتم مشابه یکدیگر (و یا مشابه با مسیرهای بهینه) هستند. در اینجا ما مسیرهای استفاده شده توسط دو رویکرد مورد مقایسه را با مسیرهای بهینه موجود در توپولوژی مفروض مقایسه می‌کنیم.

شکل (7) مقایسه عملکرد روش پیشنهادی و روش یادگیری تقویتی را به کمک نمودار جعبه‌ای بر اساس توزیع داده‌ها، میانه و دامنه مقادیر نمایش می‌دهد. در شکل (6)، میانگین روش پیشنهادی حدود $0/9$ با انحراف معیار $0/05$ است که نشان‌دهنده شباهت بالای مسیرها در این روش با مسیرهای بهینه است. در مقابل، روش یادگیری تقویتی با میانگین $0/8$ و انحراف معیار $0/1$ عملکرد ضعیف‌تری دارد. از نظر میانگین، روش پیشنهادی شباهت مسیر بیشتری دارد و از نظر پراکندگی، روش یادگیری تقویتی تنوع بیشتری دارد، که نشان از ناپایداری بیشتر آن در شرایط مختلف است. در مجموع، نتایج به دست آمده نشان می‌دهد که روش پیشنهادی در معیار شباهت مسیر عملکرد بهتری دارد.



شکل (7): مقایسه دو روش با معیار شباهت مسیر

مراحل را نشان می‌دهد. هر چه مقدار پاداش تجمعی بیشتری حاصل شود، عملکرد الگوریتم بهتر است.




شکل (6): همگرایی رویکرد پیشنهادی

رویکرد پیشنهادی مبتنی بر GAN، مسیرهای بهینه‌ای را که در الگوریتم یادگیری Q-بیشترین پاداش تجمعی را کسب کرده‌اند، مجدد به چرخه یادگیری و مسیریابی وارد می‌کند. این فرآیند با حفظ یک هم‌بندی گراف از گره‌های مفید، پایداری مسیرهای بهینه را در مراحل مختلف تضمین می‌کند. با این حال، در صورت کاهش انرژی گره‌های محبوب در مسیرهای پرتردد، الگوریتم به سرعت مسیرهای جایگزین، حتی اگر طولانی‌تر باشند، پیشنهاد می‌دهد. در نهایت، با توجه به اینکه همگرایی این رویکرد بر اساس پاداش دریافتی تنظیم شده، عملکرد مطلوبی از نظر همگرایی نشان می‌دهد. رویکرد پیشنهادی مبتنی بر GAN، مسیرهای بهینه‌ای را که در الگوریتم یادگیری Q-بیشترین پاداش تجمعی را کسب کرده‌اند، مجدد به چرخه یادگیری و مسیریابی وارد می‌کند. این فرآیند با حفظ یک هم‌بندی گراف از گره‌های مفید، پایداری مسیرهای بهینه را در مراحل مختلف تضمین می‌کند. با این حال، در صورت کاهش انرژی گره‌های محبوب در مسیرهای پرتردد، الگوریتم به سرعت مسیرهای جایگزین، حتی اگر طولانی‌تر باشند، پیشنهاد می‌دهد. در نهایت، با توجه به اینکه همگرایی این رویکرد بر اساس پاداش دریافتی تنظیم شده، عملکرد مطلوبی از نظر همگرایی نشان می‌دهد.

3.2.4. حفظ توپولوژی گراف

معیار حفظ توپولوژی گراف (Graph Topology Preservation) در عمل میزان حفظ ساختار اولیه گراف را در فرآیند مسیریابی یا شبیه‌سازی ارزیابی می‌کند. هدف از حفظ توپولوژی گراف این است که یک الگوریتم مسیریابی، مسیرهای مناسب را انتخاب کند یا تغییرات مورد نیاز را اعمال کند، بدون اینکه توپولوژی کلی شبکه (مثل تعداد و نوع ارتباطات اصلی بین گره‌ها) تغییرات عمده‌ای پیدا کند. به عبارت دیگر، مسیریابی باید به گونه‌ای انجام شود که شبکه همچنان ساختار اولیه خود را حفظ کند و پایداری و هماهنگی آن به هم نخورد. شکل (8) دو روش مورد نظر را از نظر حفظ توپولوژی گراف با هم مقایسه می‌کند.



شکل (8): مقایسه دو روش با معیار حفظ توپولوژی گراف

همان‌طور که در شکل (8) نمایان است، عملکرد روش پیشنهادی با خط آبی نشان می‌دهند که روش پیشنهادی به طور کلی عملکرد بهتری در حفظ توپولوژی گراف دارد. شایان ذکر است با گذر زمان و افزایش مصرف انرژی در گره‌های مختلف، تعدادی از گره‌های شبکه به تدریج با اتمام ذخایر انرژی خود از کار خواهند افتاد و خاموش می‌شوند. این پدیده نه تنها به کاهش تعداد گره‌های فعال در شبکه منجر می‌شود، بلکه تغییرات قابل توجهی را در توپولوژی گراف شبکه ایجاد می‌کند. حذف گره‌ها از ساختار شبکه می‌تواند موجب قطع ارتباط بین بخش‌هایی از شبکه شود و دسترسی به برخی مسیرهای موجود را غیرممکن سازد.

این تغییرات ممکن است به شکل محلی یا گسترده بر عملکرد شبکه تاثیر بگذارند، به ویژه اگر گره‌های کلیدی یا گره‌هایی که در مسیرهای پرتردد قرار دارند خاموش شوند. در چنین شرایطی، مسیریابی داده‌ها با چالش بیشتری مواجه می‌شود و الگوریتم‌های شبکه باید با بهره‌گیری از مکانیزم‌های تطبیقی به سرعت خود را با توپولوژی جدید سازگار کنند. علاوه بر این، کاهش تعداد گره‌های فعال می‌تواند تاثیر مستقیمی بر بهره‌وری کلی شبکه، از جمله نرخ تحویل بسته‌ها و افزایش تاخیر آنها به انتها داشته باشد.

4.2.4. تعداد بسته‌های تحویل شده به مقصد

این معیار درصد بسته‌های ارسالی که سالم به مقصد تحویل شده‌اند را ارزیابی می‌کند. نتایج حاصل از شبیه‌سازی برای دو رویکرد مورد مقایسه، به ازای نرخ‌های متفاوت ارسال داده در کل شبکه، در جدول (2) نشان داده شده است.

جدول (3): مقایسه نرخ تحویل بسته‌ها به مقصد

نرخ ترافیک ورودی	نرخ تحویل بسته‌ها به مقصد	
	رویکرد پیشنهادی	یادگیری تقویتی [21]
100 Kbps	98.1%	96.3%
150 Kbps	96.5%	95.0%
200 Kbps	95.1%	93.8%
250 Kbps	93.5%	92.0%
300 Kbps	92.2%	90.3%

همان‌طور که در جدول (2) نمایان است، رویکرد پیشنهادی به دلیل استفاده از مسیرهای مناسب‌تر، نرخ تحویل بالاتری نسبت به رویکرد مقابل را به ارمغان می‌آورد. روش پیشنهادی با حفظ مصرف انرژی در سطح مشابه، تعداد بیشتری از بسته‌ها را به مقصد رسانده است. این به دلیل انتخاب مسیرهای طولانی‌تر برای جریان‌های مختلف است که با توزیع مناسب بار ترافیکی میان گره‌ها از تمرکز بیش از حد مصرف انرژی در گره‌های خاص جلوگیری کرده است. این توزیع متوازن انرژی در سراسر شبکه موجب کاهش فشار بر گره‌های خاص و در نتیجه بهبود نرخ تحویل بسته‌ها شده است.

5.2.4. تاخیر انتها به انتها

میانگین تاخیر انتها به انتها یکی از مهمترین معیارهایی است که می‌توان دو رویکرد مسیریابی مورد نظر را با یکدیگر مقایسه کرد. جدول (4) نتایج به دست آمده از شبیه‌سازی را نشان می‌دهد. همان‌طور که در این جدول مشاهده می‌شود، میانگین تاخیر انتها به انتها برای بسته‌های ارسال شده در رویکرد پیشنهادی به دلیل استفاده از مسیرهای مناسب‌تر، از رویکرد مقابل کمتر است.

جدول (4): مقایسه میانگین تاخیر انتها به انتها


نرخ ترافیک ورودی	میانگین تاخیر انتها به انتها	
	رویکرد پیشنهادی	یادگیری تقویتی [21]
100 Kbps	1.25 s	1.58 s
150 Kbps	1.37 s	1.71 s
200 Kbps	1.55 s	1.96 s
250 Kbps	1.84 s	2.34 s
300 Kbps	2.21 s	2.79 s

به طور شهودی می‌توان گفت دلیل کاهش تاخیر انتها به انتها در رویکرد پیشنهادی در مقایسه با رویکرد رقیب، بهره‌گیری از مسیرهای بهینه‌تر و استفاده از یادگیری مبتنی بر GAN است. این رویکرد با ترکیب قدرت یادگیری تقویتی و توانایی شبکه‌های مولد تخصصی در مدل‌سازی پیچیدگی‌های محیطی، امکان انتخاب مسیرهایی را فراهم می‌کند که نه تنها کوتاه‌تر هستند، بلکه با در نظر گرفتن شرایط واقعی شبکه، مانند تراکم گره‌ها، مصرف انرژی و تاخیر انتقال داده، کارآمدتر نیز عمل می‌کنند. GAN در این فرآیند به شبیه‌سازی و پیش‌بینی بهتر رفتار شبکه کمک می‌کند و با تولید داده‌های مصنوعی نزدیک به واقعیت، الگوریتم یادگیری تقویتی را به سمت انتخاب تصمیمات دقیق‌تر هدایت می‌کند. این ترکیب هوشمندانه از یادگیری تقویتی و GAN، منجر به کاهش قابل توجه تاخیر انتها به انتها می‌شود، زیرا مسیرهای انتخاب شده به گونه‌ای طراحی می‌شوند که کمترین مانع و بیشترین بازدهی را در انتقال داده‌ها داشته باشند. علاوه بر این، رویکرد پیشنهادی توانایی انطباق با تغییرات شبکه

را نیز داراست؛ به این معنا که در صورت تغییر شرایط مانند خرابی گره‌ها یا افزایش بار ترافیکی، به سرعت می‌تواند مسیرهای جدید و بهینه‌تری را پیشنهاد کند. این ویژگی، عملکرد پایدارتر و کاهش تاخیر بیشتری را نسبت به روش‌های سنتی تضمین می‌کند.

6.2.4. طول عمر شبکه

برای مقایسه طول عمر شبکه و میزان مصرف انرژی در دو رویکرد مدنظر، تعداد گره‌های زنده مانده در برابر تعداد گره‌های خاموش شده در طول شبیه‌سازی به دقت اندازه‌گیری شدند. گره‌های شبکه انرژی اولیه خود را برای انجام محاسبات و ارتباطات خود مصرف می‌کنند. شکل (9) تعداد گره‌های زنده در طول مدت شبیه‌سازی را برای دو رویکرد نشان می‌دهد.



شکل (9): مقایسه درصد گره‌های زنده در طول شبیه‌سازی

همان‌طور که در شکل (9) نشان داده شده است، در رویکرد یادگیری تقویتی همواره تعداد گره‌های زنده در شبکه قدری بیشتر از رویکرد پیشنهادی است و در عمل شبکه طول عمر بالاتری دارد. این امر نشان از کمتر بودن مصرف انرژی در گره‌های شبکه در رویکرد یادگیری تقویتی نسبت به رویکرد پیشنهادی دارد. در رویکرد پیشنهادی به دلیل محاسبات بالاتر در طول روال یادگیری، گره‌ها قدری انرژی بیشتری مصرف می‌کنند. در کارهای آتی ما قصد داریم تمرکز بیشتری بر روی کاهش مصرف انرژی در رویکرد پیشنهادی قرار دهیم.

5. نتیجه‌گیری

مصنوعی و ترکیب آنها با داده‌های واقعی استفاده شد. این رویکرد موجب افزایش حجم داده‌های آموزشی و بهبود عملکرد الگوریتم‌های یادگیری ماشین و پروتکل‌های مسیریابی در شبکه‌های حسگر بی‌سیم زیرآبی شد که به دلیل محدودیت تعداد گره‌ها و داده‌ها، نیازمند بهینه‌سازی بودند. در نهایت، روش پیشنهادی با روش مبتنی بر یادگیری تقویتی مقایسه گردید. نتایج شبیه‌سازی نشان داد که روش پیشنهادی از نظر معیارهایی همچون شباهت مسیرها، حفظ توپولوژی شبکه، پاداش تجمعی، نرخ بسته‌های تحویلی و میزان تاخیر انتها به انتها عملکرد بهتری نسبت به روش یادگیری تقویتی داشته است و در مقابل قدری مصرف انرژی در گره‌های شبکه را افزایش می‌دهد.

تعارض منافع: نویسندگان اعلام می‌کنند که هیچ تعارض منافعی ندارند.

در این مقاله، با در نظر گرفتن معیارهای مهمی مانند انرژی باقیمانده حسگرها و کاهش تاخیر، و با توجه به رفتار عامل‌ها در پژوهش‌های مختلف مبتنی بر یادگیری عمیق، تعداد زیادی مسیر بهینه برای مسیریابی داده در شبکه‌های حسگر بی‌سیم زیرآبی شناسایی و ذخیره شد. سپس، این مسیرها به منظور آموزش شبکه عمیق متخاصم زایشی بکار گرفته شدند. فرآیند آموزش به صورت آفلاین و در دستگاه‌هایی با منابع پردازشی کافی انجام گرفت و مدل به دست آمده برای مسیریابی داده‌ها در حسگرهای بی‌سیم زیرآبی مورد استفاده قرار گرفت. در مرحله انتقال داده، مسیر بهینه بر اساس وضعیت پویای گره حسگر فعلی تولید شد، که این امر منجر به ایجاد الگوریتمی پویا گردید که قادر به تصمیم‌گیری بر اساس شرایط جاری هر گره است. هدف اصلی این الگوریتم، یافتن مسیرهای بهینه با مصرف انرژی بهینه برای حسگرها بود. علاوه بر این، از شبکه GAN برای تولید داده‌های

مراجع

- [1] A. Tavakoli and A. Keshavarz-Haddad, "A Survey on the Characteristics of Communication Technologies in Smart Homes and the Challenges Ahead," *Soft Comput. J.*, vol. 12, no. 2, pp. 36-53, 2024, doi: 10.22052/scj.2023.242846.0 [In Persian].
- [2] S. Ashkezari, M. N. Teimoori, and V. Sabzevari, "Localization of Mobile Targets in a Wireless Sensor Network Using Diffusion Least Mean Square Algorithm Based on Huber Loss Function," *Soft Comput. J.*, vol. 13, no. 1, pp. 58-75, 2024, doi: 10.22052/scj.2023.252719.1141 [In Persian].
- [3] F. Campagnaro, F. Steinmetz, and B. C. Renner, "Survey on Low-Cost Underwater Sensor Networks: From Niche Applications to Everyday Use," *J. Mar. Sci. Eng.*, vol. 11, no. 1, p. 125, 2023, doi: 10.3390/jmse11010125.
- [4] H. Luo, J. Wang, F. Bu, R. Ruby, K. Wu, and Z. Guo, "Recent Progress of Air/Water Cross-Boundary Communications for Underwater Sensor Networks: A Review," *IEEE Sensors J.*, vol. 22, no. 9, pp. 8360-8382, 2022, doi: 10.1109/JSEN.2022.3162600.
- [5] S. Gupta and N. P. Singh, "Underwater Wireless Sensor Networks: A Review of Routing Protocols, Taxonomy, and Future Directions," *J. Supercomput.*, vol. 80, no. 4, pp. 5163-5196, 2024, doi: 10.1007/s11227-023-05646-w.
- [6] S. Khisa and S. Moh, "Survey on Recent Advancements in Energy-Efficient Routing Protocols for Underwater Wireless Sensor Networks," *IEEE Access*, vol. 9, pp. 55045-55062, 2021, doi: 10.1109/ACCESS.2021.3071490.
- [7] Z. Liu, X. Jin, Y. Yang, K. Ma, and X. Guan, "Energy-Efficient Guiding-Network-Based Routing for Underwater Wireless Sensor Networks," *IEEE Internet Things J.*, vol. 9, no. 21, pp. 21702-21711, 2022, doi: 10.1109/JIOT.2022.3183128.

- [8] H. Khan, S. A. Hassan, and H. Jung, "On Underwater Wireless Sensor Networks Routing Protocols: A Review," *IEEE Sensors J.*, vol. 20, no. 18, pp. 10371-10386, 2020, doi: 10.1109/JSEN.2020.2994199.
- [9] J. Gui, Z. Sun, Y. Wen, D. Tao, and J. Ye, "A Review on Generative Adversarial Networks: Algorithms, Theory, and Applications," *IEEE Trans. Knowl. Data Eng.*, vol. 35, no. 4, pp. 3313-3332, 2023, doi: 10.1109/TKDE.2021.3130191.
- [10] O. L. Striuk and Y. U. Kondratenko, "Generative Adversarial Neural Networks and Deep Learning: Successful Cases and Advanced Approaches," *Int. J. Comput.*, vol. 20, no. 3, pp. 339-349, 2021, doi: 10.47839/ijc.20.3.2278.
- [11] K. K. Gola and S. Arya, "Underwater Acoustic Sensor Networks: Taxonomy on Applications, Architectures, Localization Methods, Deployment Techniques, Routing Techniques, and Threats: A Systematic Review," *Concurrency Computat. Pract. Exper.*, vol. 35, no. 23, p. e7815, 2023, doi: 10.1002/cpe.7815.
- [12] J. Luo, Y. Chen, M. Wu, and Y. Yang, "A Survey of Routing Protocols for Underwater Wireless Sensor Networks," *IEEE Commun. Surveys Tuts.*, vol. 23, no. 1, pp. 137-160, 2021, doi: 10.1109/COMST.2020.3048190.
- [13] R. W. L. Coutinho, A. Boukerche, L. F. M. Vieira, and A. A. F. Loureiro, "Geographic and Opportunistic Routing for Underwater Sensor Networks," *IEEE Trans. Comput.*, vol. 65, no. 2, pp. 548-561, 2016, doi: 10.1109/TC.2015.2423677.
- [14] G. Tuna, "Clustering-Based Energy-Efficient Routing Approach for Underwater Wireless Sensor Networks," *Int. J. Sensor Netw.*, vol. 27, no. 1, pp. 26-36, 2018, doi: 10.1504/IJSNET.2018.092114.
- [15] M. U. Khan, P. Otero, and M. Aamir, "An Energy Efficient Clustering Routing Protocol Based on Arithmetic Progression for Underwater Acoustic Sensor Networks," *IEEE Sensors J.*, vol. 24, no. 5, pp. 6964-6975, 2024, doi: 10.1109/JSEN.2024.3354252.
- [16] Y. Sun, M. Zheng, X. Han, S. Li, and J. Yin, "Adaptive Clustering Routing Protocol for Underwater Sensor Networks," *Ad Hoc Netw.*, vol. 136, p. 102953, 2022, doi: 10.1016/j.adhoc.2022.102953.
- [17] R. Zhu, A. Boukerche, Y. Chen, and Q. Yang, "A Reliable Cluster-Based Opportunistic Routing Protocol for Underwater Wireless Sensor Networks," *Comput. Netw.*, vol. 251, p. 110622, 2024, doi: 10.1016/j.comnet.2024.110622.
- [18] W. Zhu, X. Yang, T. Wu, and Y. Qiu, "A Routing Algorithm for Underwater Acoustic-Optical Hybrid Wireless Sensor Networks Based on Intelligent Ant Colony Optimization and Energy-Flexible Global Optimal Path Selection," *IEEE Sensors J.*, vol. 24, no. 10, pp. 17116-17126, 2024, doi: 10.1109/JSEN.2024.3386892.
- [19] X. Xiao, H. Huang, and W. Wang, "Underwater Wireless Sensor Networks: An Energy-Efficient Clustering Routing Protocol Based on Data Fusion and Genetic Algorithms," *Appl. Sci.*, vol. 11, no. 1, p. 312, 2020, doi: 10.3390/app11010312.
- [20] D. Han et al., "Trust-Aware and Fuzzy Logic-Based Reliable Layering Routing Protocol for Underwater Acoustic Networks," *Sensors*, vol. 23, no. 23, p. 9323, 2023, doi: 10.3390/s23239323.
- [21] A. Khasawneh, M. S. B. A. Latiff, O. Kaiwartya, and H. Chizari, "A Reliable Energy-Efficient Pressure-Based Routing Protocol for Underwater Wireless Sensor Network," *Wireless Netw.*, vol. 24, no. 6, pp. 2061-2075, 2018, doi: 10.1007/s11276-017-1461-x.
- [22] L. Alsalman and E. Alotaibi, "A Balanced Routing Protocol Based on Machine Learning for Underwater Sensor Networks," *IEEE Access*, vol. 9, pp. 152082-152097, 2021, doi: 10.1109/ACCESS.2021.3126107.
- [23] Y. Su, R. Fan, X. Fu, and Z. Jin, "DQELR: An Adaptive Deep Q-Network-Based Energy- and Latency-Aware Routing Protocol Design for Underwater Acoustic Sensor Networks," *IEEE Access*, vol. 7, pp. 9091-9104, 2019, doi: 10.1109/ACCESS.2019.2891590.
- [24] X. Zhu et al., "Dynamic Layered Routing

Protocols Based on BP-NN for Underwater Acoustic Sensor Networks,” *Appl. Acoust.*, vol. 211, p. 109454, 2023, doi: 10.1016/j.apacoust.2023.109454.

[25] C. Wang, X. Shen, H. Wang, H. Zhang, and H. Mei, “Reinforcement Learning-Based Opportunistic Routing Protocol Using Depth Information for Energy-Efficient Underwater Wireless Sensor Networks,” *IEEE Sensors J.*, vol. 23, no. 15, pp. 17771-17783, 2023, doi: 10.1109/JSEN.2023.3285751.

[26] Y. Yuan et al., “A Q-Learning-Based Hierarchical Routing Protocol with Unequal Clustering for Underwater Acoustic Sensor Networks,” *IEEE Sensors J.*, vol. 23, no. 6, pp. 6312-6325, 2023, doi: 10.1109/JSEN.2022.3232614.

[27] C. Wang et al., “Multi-Agent Reinforcement Learning-Based Routing Protocol for Underwater Wireless Sensor Networks with Value of Information,” *IEEE Sensors J.*, vol. 24, no. 5, pp. 7042-7054, 2024, doi: 10.1109/JSEN.2023.3347101.