

Research Article

Performance Comparison of Cache Algorithms in Named Data Networks Focusing on Contamination Attack Mitigation and β Parameter Optimization

Atefeh Vaez Sharestni ¹  | Mohammad Reza Khayam bashi ^{*2}  | Farmarz Safi ³ 

¹Faculty of Computer Engineering, Najafabad Branch, Islamic Azad University, Najafabad, Iran, Atefehvaez@gmail.com

²Faculty of Computer Engineering, University of Isfahan, Isfahan, Iran, M.r.khayambashi@eng.ui.ac.ir

³Big Data Research Center, Najafabad Branch, Islamic Azad University, Najafabad, Iran, Fsafi@iaun.ac.ir

Corresponding Author

***Mohammad Reza Khayam bashi**, professor, Faculty of Computer Engineering, University of Isfahan, Isfahan, Iran, M.r.khayambashi@eng.ui.ac.ir

Main Subject: Comparison of Cache Algorithms

Received: 5 June 2025

Accepted: 10 July 2025

Abstract

Intelligent cache management in Named Data Networks (NDN) is a critical component in optimizing network performance and enhancing the quality of user experience. Tuning cache sensitivity based on behavioral changes using the β parameter and Zipf distribution is very important in cache management. Considering that β has a direct effect on the balance between resistance to pesticide contamination and keeping the real popular content, setting and determining this parameter plays a fundamental role. In this research, a new framework based on the algorithm of directed incremental Lagrange multipliers (ADMM) is presented for distributed and adaptive adjustment of β parameter. The proposed model with a decentralized structure can be implemented at the level of network nodes and leads to fast convergence and precise adjustment of β through coordinated updates of primary and secondary variables. In addition, a more advanced version called ADMM-Enhanced has been developed, which achieves more stability, accuracy and adaptability to network dynamic conditions by using the automatic adjustment of λ and ρ parameters. To evaluate the efficiency of this method, four network topologies

(simple, hierarchical, advanced and mesh) were designed and simulated in different scenarios. The simulation results and comparison with the reference algorithms showed that the ADMM-Enhanced algorithm in the stable scenario increased the hit rate by 30% and reduced the contamination to zero. In the face of severe attack (30% attacker), it has shown stable, adaptable and resistant performance by maintaining CHR equal to 18% and CPR equal to 18%. Also, in complex topologies such as mesh, the proposed algorithm was able to maintain cache efficiency and quality against distributed threats, congestion and link interruption, and showed high compatibility with dynamic environments.

Keywords: ADMM Algorithm, ADMM-Enhanced, Named Data Networks, Cache Memory, Cache Hit Rate, Cache Pollution Percentage

<https://doi.org/10.82195/ntds.2025.1208980>

پژوهشی

مقایسه عملکرد الگوریتم های گش در شبکه های داده های نام گذاری شده با تمرکز بر کاهش حملات آلودگی و بهینه سازی پارامتر β عاطفه واعظ شهرستانی^۱ | محمدرضا خیام باشی^{۲*} | فرامرز صافی^۳ 

چکیده:

مدیریت هوشمند حافظه نهان در شبکه های داده های نام گذاری شده (NDN)، یک مؤلفه حیاتی در بهینه سازی کارایی شبکه و ارتقای کیفیت تجربه کاربر است. تنظیم حساسیت گش بر اساس تغییرات رفتاری با استفاده از پارامتر β و توزیع Zipf در مدیریت حافظه نهان بسیار مهم است. با توجه به اینکه β تأثیر مستقیمی بر تعادل میان مقاومت در برابر آلودگی گش و حفظ محتوای واقعی محبوب دارد، تنظیم و تعیین این پارامتر نقشی بنیادین ایفا می کند. در این پژوهش، چارچوبی نوین مبتنی بر الگوریتم روش ضرایب لاگرانژ افزایشی جهت دار (ADMM) برای تنظیم توزیع شده و تطبیقی پارامتر β ارائه شده است. مدل پیشنهادی با ساختاری غیرمتمرکز، قابلیت اجرا در سطح گره های شبکه را داراست و از طریق به روزرسانی های هماهنگ متغیرهای اولیه و دوگانه، به همگرایی سریع و تنظیم دقیق β منتهی می شود. افزون بر آن، نسخه پیشرفته تری تحت عنوان-ADMM-Enhanced توسعه یافته است که با بهره گیری از تنظیم خودکار پارامترهای ρ ، پایداری، دقت و تطبیق پذیری بیشتری نسبت به شرایط دینامیک شبکه حاصل می کند. برای ارزیابی کارایی این روش، چهار توپولوژی شبکه (ساده، سلسله مراتبی، پیشرفته و مش) در سناریوهای مختلف طراحی و شبیه سازی شد. نتایج شبیه سازی و مقایسه با الگوریتم های مرجع نشان دادند که الگوریتم ADMM-Enhanced در سناریوی پایدار نرخ اصابت گش را تا ۳۰٪ افزایش داده و آلودگی را به صفر رسانده است، و در مواجهه با حمله شدید (۳۰٪ مهاجم) نیز با حفظ CHR برابر ۱۸٪ و CPR برابر ۱۸٪، عملکردی پایدار، تطبیق پذیر و مقاوم از خود نشان داده است. همچنین در توپولوژی های پیچیده مانند مش، الگوریتم پیشنهادی توانست در برابر تهدیدات توزیع شده، ازدحام و قطع لینک، بهره وری و کیفیت گش را حفظ کرده و سازگاری بالایی با محیط های پویا از خود نشان دهد.

^۱ گروه مهندسی کامپیوتر، واحد نجف آباد، دانشگاه آزاد اسلامی، نجف آباد، ایران،

Atefehvaez@gmail.com

^۲ استاد، دانشکده مهندسی کامپیوتر، دانشگاه اصفهان، اصفهان، ایران،

M.r.khayyambashi@eng.ui.ac.ir

^۳ مرکز تحقیقات کلان داده، واحد نجف آباد، دانشگاه آزاد اسلامی، نجف آباد، ایران،

Fsafi@iaun.ac.ir

نویسنده مسئول

^{*} محمدرضا خیام باشی، استاد دانشکده مهندسی کامپیوتر، دانشگاه اصفهان، اصفهان، ایران،

M.r.khayyambashi@eng.ui.ac.ir

عنوان اصلی: عملکرد الگوریتم های گش

تاریخ دریافت: ۱۵ خرداد ۱۴۰۴

تاریخ پذیرش: ۱۹ تیر ۱۴۰۴

<https://doi.org/10.82195/ntds.2025.1208980>

کلیدواژه ها: الگوریتم ADMM-Enhanced، شبکه های داده های نام گذاری شده، حافظه نهان، نرخ اصابت گش، درصد آلودگی گش

۱-مقدمه

در دهه های اخیر، شبکه های رایانه ای با رشد بی سابقه حجم داده ها، کاربران و تنوع کاربردهای اینترنتی مواجه شده اند. معماری سنتی اینترنت که بر پایه مدل میزبان محور و آدرس دهی IP طراحی شده است، در پاسخ گویی به نیازهای جدیدی نظیر تحویل محتوای سریع، انعطاف پذیر، امن و مقیاس پذیر، با چالش های متعددی روبه رو شده است [۱]. در پاسخ به این چالش ها، معماری های نوین با رویکرد محتوامحور^۱ (ICN) مطرح شده اند که در آن ها تمرکز اصلی از «مکان محتوا» به «نام محتوا» منتقل می شود [۲، ۳]. یکی از مهم ترین نمونه های معماری های محتوامحور، شبکه داده های نام گذاری شده^۲ (NDN) است. در این معماری، داده ها به صورت مستقل از مکان، نام گذاری شده و از طریق بسته های درخواستی و داده بین گره ها رد و بدل می شوند. یکی از مزایای کلیدی NDN، بهره گیری از حافظه نهان بین راهی در تمامی گره ها است. این قابلیت منجر به کاهش تأخیر واکشی داده، کاهش بار سرورها، صرفه جویی در پهنای باند و افزایش کارایی شبکه می شود [۴، ۵].

با این حال، همین ویژگی مفید می تواند نقطه ضعف امنیتی نیز باشد. یکی از تهدیدات مهم در NDN، حملات آلودگی حافظه نهان^۳ (CPA) است. در این نوع حملات، مهاجم با ارسال درخواست های مکرر برای محتوای نامحسوب یا جعلی، موجب می شود داده های پر کاربرد از کش خارج شده و فضای کش با داده های کم ارزش پر شود. این فرآیند به کاهش نرخ اصابت کش، افت کارایی کلی شبکه و افزایش تأخیر پاسخ گویی می انجامد. بسیاری از سیاست های کش سنتی مانند کمترین استفاده اخیر LRU^۴ و کمترین استفاده شده به طور مکرر^۵ LFU، به دلیل عدم توجه به الگوهای رفتاری مهاجمین یا منشأ درخواست ها، در برابر این نوع حملات آسیب پذیر هستند [۷، ۸].

در سال های اخیر، الگوریتم هایی با هوشمندی بالاتر طراحی شده اند تا با حملات آلودگی حافظه نهان مقابله کنند. یکی از نوآورانه ترین این الگوریتم ها، الگوریتم محبوبیت به ازای هر ورودی^۶ (PFP) است که با نرمال سازی سهم محبوبیت بین مسیرهای ورودی مختلف، از تمرکز مصنوعی محبوبیت توسط مهاجم جلوگیری می کند [۹]. نسخه پیشرفته تر این الگوریتم، PFP با کهنگی پویا (PFP-DA)، عامل زمان و میزان استفاده مجدد را نیز در تصمیم گیری دخیل می سازد [۱۰، ۱۱]. همچنین، نسخه بهینه شده این الگوریتم با استفاده از پارامتر β (PFP- β)، سعی دارد توزیع محبوبیت را مطابق با توزیع طبیعی Zipf مدل سازی کرده و دقت تشخیص را افزایش دهد [۱۲]. علیرغم تحقیقات موجود درباره حملات آلودگی حافظه نهان^۷ در شبکه های داده های نام گذاری شده (NDN)، همچنان خلأ های اساسی در این حوزه وجود دارد که نیازمند بررسی بیشتر است. از جمله این موارد می توان به فقدان الگوریتم های مقاوم در برابر حملات چندمسیره، عدم وجود مدلی برای تنظیم حساسیت کش بر اساس تغییرات رفتاری با استفاده از پارامتر β و توزیع Zipf، ابهام در نقش توزیع محبوبیت و تنوع ترافیک در آسیب پذیری کش، کمبود مدل های سبک وزن قابل پیاده سازی و مقرون به صرفه برای سناریوهای واقعی، و نبود ترکیب مؤثر سیاست های جایگزینی کش با مکانیزم های امنیتی اشاره کرد [۱۳].

با توجه به اینکه β تأثیر مستقیمی بر تعادل میان مقاومت در برابر آلودگی کش و حفظ محتوای واقعی محبوب دارد، انتخاب مقدار مناسب آن در شرایط پویا و متغیر شبکه به صورت دستی یا استاتیک نه تنها دشوار بلکه ناکارآمد است. یکی از راهکارهای مؤثر برای تعیین مقدار بهینه پارامتر β ، بهره گیری از روش های بهینه سازی هوشمند و خود تطبیقی است. به طور کلی، تکنیک های بهینه سازی موجود را می توان به الگوریتم های قطعی^۸ و الگوریتم های فراابتکاری^۹ (MAS) دسته بندی کرد [۱۴]. الگوریتم های قطعی توابع ریاضی خاصی هستند و به صورت مکانیکی و تکراری بدون هیچ گونه ماهیت تصادفی کار می کنند. در یک مسئله معین، یک روش قطعی همیشه خروجی یکسانی را برای یک ورودی خاص به دست می آورد. گرادیان^{۱۰} نزولی و روش های نیوتن^{۱۱}

¹ Information-Centric Networking² Named Data Networking³ Cache Pollution Attack⁴ Least Recently Used⁵ Least Frequently Used⁶ Per-Face Popularity⁷ Cache Pollution Attacks⁸ Deterministic algorithms⁹ Metaheuristic algorithms¹⁰ Gradient descent¹¹ Newton's methods

دو نمونه کلاسیک از الگوریتم‌های قطعی هستند. از این‌رو، استفاده از الگوریتم‌های بهینه‌سازی مبتنی بر جست‌وجوی هوشمند مانند الگوریتم‌های تکاملی^۱، بهینه‌سازی ازدحام ذرات^۲ (PSO)، الگوریتم ژنتیک (GA) یا روش‌هایی چون بهینه‌سازی بیزی^۳ و روش‌های قطعی می‌تواند رویکردی کارآمد برای تنظیم خودکار β باشد [۱۵، ۱۶]. هدف اصلی این روش‌ها، یافتن مقداری از β است که در یک بازه مشخص (مثلاً بین ۰.۰۱ تا ۱) بیشترین کارایی را در مقابله با حملات آلودگی کش و بیشترین نرخ اصابت را در محیط شبکه ارائه دهد. این روش‌ها می‌توانند با ارزیابی مکرر عملکرد الگوریتم در پاسخ به سناریوهای مختلف حمله، مقادیر مختلف β را بررسی کرده و بهترین مقدار را در هر مرحله تعیین کنند. برخی از این الگوریتم‌ها حتی قادرند به صورت بلادرنگ و در زمان اجرای سیستم، با توجه به داده‌های ورودی جاری از شبکه (مانند میزان نوسان نرخ اصابت، نسبت خطا، تأخیر واکنشی داده و ...) مقدار β را بازتنظیم کرده و خود را با شرایط جدید تطبیق دهند [۱۷].

روش ضرب‌کننده‌های لاگرانژ تفکیکی متناوب^۴ (ADMM) برای مسائل بهینه‌سازی مقید و محدب با ساختارهای تجزیه‌پذیر مناسب است. استفاده از ADMM در تعیین مقدار بهینه پارامتر β در الگوریتم PFP- β ، مزایای قابل توجهی را در زمینه همگرایی پایدار، تحلیل‌پذیری و تطبیق‌پذیری فراهم می‌سازد [۱۸].

در مسئله بهینه‌سازی تعیین مقدار β باید به گونه‌ای تنظیم شود که بین دو هدف متضاد یعنی کاهش میزان آلودگی کش و حفظ نرخ بالای اصابت محتوا توازن برقرار گردد. این امر را می‌توان به صورت یک مسئله بهینه‌سازی دوجزئی مدل‌سازی کرد که در آن تابع هدف از دو مؤلفه تشکیل می‌شود: یکی نمایانگر ضریب آلودگی حافظه نهان و دیگری نمایانگر نرخ اصابت کش. با استفاده از ADMM، می‌توان این دو مؤلفه را به صورت جداگانه مدل کرده، سپس به طور هم‌زمان و هماهنگ از طریق به‌روزرسانی‌های تکراری پارامتر β را در هر گام به گونه‌ای تنظیم کرد که تعادل بهینه حاصل شود. از آنجاکه ساختار PFP- β به طور ذاتی بر پایه تجمیع و نرمال‌سازی محبوبیت محتوا از چندین درگاه ورودی - خروجی است، استفاده از ADMM این امکان را فراهم می‌سازد که این تجمیع در هر درگاه به صورت موازی انجام شده و در نهایت نتایج بهینه‌سازی از طریق یک گام تلفیق^۵ یکپارچه شوند. در چنین حالتی، هر Face نقش یک عامل محلی را ایفا می‌کند که در بهینه‌سازی شرکت دارد و مقدار β نهایی از طریق مشارکت توزیعی تمامی بخش‌ها حاصل می‌شود.

هدف پژوهش حاضر، طراحی و ارزیابی یک مدل بهینه مبتنی بر بهینه‌ساز ADMM جهت بهبود مدیریت کش و مقاوم‌سازی آن در برابر حملات آلودگی حافظه نهان در معماری NDN است. در این تحقیق، با استفاده از الگوریتم PFP-DA و افزودن پارامتر تنظیمی β ، نسخه‌ای بهینه‌سازی شده از این الگوریتم ارائه خواهد شد که قادر است به طور مؤثر با حملات آلودگی حافظه نهان مقابله کرده و کارایی شبکه را بهبود بخشد. علاوه بر این، این تحقیق قصد دارد با ارائه یک راهکار سبک‌وزن و قابل‌پیاده‌سازی در شبیه‌ساز ndnSIM، امکان استفاده عملی از مدل پیشنهادی را در سناریوهای واقعی فراهم کند؛ بنابراین نوآوری‌های این مقاله عبارت است از:

- ارائه نسخه پارامتریک PFP- β از الگوریتم PFP-DA با قابلیت تنظیم رفتار کش بر اساس پارامتر β
 - مدل‌سازی دقیق توزیع محبوبیت محتوا مطابق با توزیع Zipf با استفاده از پارامتر β
 - استفاده از روش ADMM (تقسیم‌بندی ضرب آدم) برای بهینه‌سازی پارامتر β و تصمیم‌گیری کش به صورت سریع و مقیاس‌پذیر
- ساختار این مقاله به گونه‌ای طراحی شده است که در بخش دوم، پیشینه پژوهش مرتبط با حملات آلودگی کش در معماری NDN به صورت جامع بررسی می‌شود. در بخش سوم، جزئیات روش پیشنهادی شامل الگوریتم PFP- β و کاربرد روش ADMM برای بهینه‌سازی پارامتر β به طور کامل تشریح خواهد شد. بخش چهارم نیز به ارائه نتایج تجربی به دست آمده از شبیه‌سازی در محیط ndnSIM و تحلیل‌های کمی و کیفی مربوط به عملکرد الگوریتم اختصاص دارد. در نهایت، در بخش پنجم، نتیجه‌گیری نهایی مقاله ارائه شده و پیشنهادهایی برای پژوهش‌های آتی مطرح می‌گردد.

¹ Evolutionary Algorithms² Particle Swarm Optimization (PSO)³ Bayesian Optimization⁴ Alternating Direction Method of Multipliers⁵ Consensus update

۲- پیشینه تحقیق

مطالعه‌ای توسط ماندپاتی و راناورا^۱ در این پژوهش نشان می‌دهند که سیاست‌های کش سنتی مانند LRU، به دلیل تمرکز صرف بر فراوانی استفاده، قادر به تمایز بین محتوای معتبر و درخواست‌های مخرب نیستند. آن‌ها با ترکیبی از شاخص‌های «محبوبیت محتوا» و «تازگی داده» روشی برای تشخیص زودهنگام و کاهش اثر حملات آلودگی کش در محیط IoT-NDN ارائه می‌دهند که به نرخ شناسایی ۹۶٪ دست‌یافته است. با این حال، این رویکرد موجب افزایش سربار محاسباتی در گره‌های مرزی شده و نیازمند نگهداری ساختارهای داده اضافی برای ردیابی هم‌زمان دو شاخص محبوبیت و تازگی است [۱۹].

یانگ^۲ و همکاران در سال ۲۰۲۵ طرح دفاع واکنشی پیشگیرانه ترکیبی^۳ HPR-DS را معرفی می‌کنند که با ترکیب ماژول‌های «پیشگیرانه» و «واکنشی» در لایه‌های میانی و مرزی شبکه و استفاده از تحلیل سری‌زمانی و خوشه‌بندی چندبعدی داده‌ها، خنثی‌سازی حملات^۴ (IFA) را تشخیص می‌دهد. این روش با مدیریت منابع مبتنی بر پیش‌بینی، کیفیت خدمات کاربران (QoS) را در طول فعالیت حمله حفظ می‌کند. اما پیچیدگی بالای الگوریتم، نیاز به پردازش بلادرنگ و سربار زیاد در گره‌های مرزی از جمله معایب قابل توجه آن است [۲۰].

وانگ^۵ و همکاران در سال ۲۰۲۴، مدل‌سازی رفتار انتقال محتوا به‌وسیله فرآیند مارکوف و ساخت ماتریس انتقال احتمال، تغییرات غیرعادی در تأخیر و مسیرهای داده را به‌عنوان نشانگر حملات آلودگی کش شناسایی می‌کنند. برخلاف روش‌هایی که فرض ثبات توزیع محبوبیت محتوا را در نظر می‌گیرند، این الگوریتم توانایی ارائه دقت تشخیص بالا در شبکه‌های پویا و با تغییر مداوم رفتار کاربران را دارد. با این حال، محاسبه و نگهداری ماتریس‌های انتقال بزرگ و پیچیدگی تحلیلی بالا، مقیاس‌پذیری عملی آن را محدود می‌کند [۲۱].

فیشول حامدی و همکاران^۶ در سال ۲۰۲۴ نشان می‌دهند که استفاده از یادگیری عمیق در محیط NDN می‌تواند ابزار مؤثری برای شناسایی و مهار حملات آلودگی کش باشد. آن‌ها با توسعه الگوریتمی مبتنی بر شبکه‌های عصبی عمیق در شبیه‌ساز ndnSIM الگوهای رفتاری پنهان در داده‌ها را استخراج کرده و عملکرد بهتری نسبت به تکنیک‌های کلاسیک یا الگوریتم‌های احتمال محور ارائه می‌دهند. با این وجود، پیچیدگی محاسباتی بسیار بالا، نیاز به داده‌های آموزشی گسترده و هزینه اجرایی سنگین در شبکه‌های مقیاس‌پذیر از مهم‌ترین محدودیت‌های این رویکرد محسوب می‌شود [۲۲].

جان باغ^۷ و همکاران در سال ۲۰۲۳ الگوریتم PFP را معرفی کرده‌اند که با تحلیل «محبوبیت نرمال‌شده» محتوا بر اساس سهم هر Face، از تمرکز مصنوعی محبوبیت توسط کاربران مشکوک جلوگیری می‌کند. نسخه PFP-DA با افزودن مکانیزم «کهنگی پویا» و نسخه PFP- β با به‌کارگیری پارامتر β برای شبیه‌سازی توزیع Zipf، دقت و مقاومت الگوریتم را در برابر حملات آلودگی کش افزایش می‌دهند. این الگوریتم‌ها نتایج تجربی قابل توجهی در مقایسه با روش‌های رایج مانند LRU و LFU-DA ارائه کرده‌اند، اما پیاده‌سازی آن‌ها نیازمند نگهداری ساختارهای داده جداگانه برای هر درگاه و پردازش بلادرنگ تغییرات توزیع محبوبیت است که می‌تواند در گره‌هایی با منابع محدود به چالش بیانجامد [۱۲].

عبداهاک حیدوری^۸ و همکاران در سال ۲۰۲۳ با معرفی الگوریتم Q-ICAN مبتنی بر یادگیری تقویتی، در هر روتر NDN عاملی قرار می‌دهند که با استفاده از شاخص‌هایی مانند نوسانات نرخ اصابت کش (CHR) و فاصله زمانی بین درخواست‌ها، رفتار مشروع و مخرب را فرامی‌گیرد. این روش در شبیه‌سازی‌ها به دقت تشخیص ۹۵٫۰۹٪، نرخ اصابت کش ۹۴٪ و کاهش ۱۸٪ در زمان بازبازی داده‌ها رسیده است. با این حال، نیاز به زمان طولانی برای آموزش، طراحی دقیق تابع پاداش و پیچیدگی محاسباتی بیشتر نسبت به الگوریتم‌های آماری ساده از معایب اصلی این رویکرد به شمار می‌آید [۲۳].

¹ Mandapati, Ranaweera

² Yang

³ Hybrid Proactive Reactive Defense Scheme

⁴ Interest Flooding

⁵ Wang

⁶ Fishol Hamdi

⁷ John Baugh

⁸ Abdelhak Hidouri

با لیو و پنگ^۱ در سال ۲۰۲۳ با ارائه الگوریتم BO-CatBoost که از بهینه‌سازی بیزی و ویژگی‌هایی مانند تعداد کَش از دست‌رفته و ورودی‌های PIT بهره می‌گیرد، توانسته‌اند هم‌زمان حملات آلودگی کَش و حملات پیشرفته سیل درخواست‌های هم‌دست‌شده^۲ (I-CIFA) را تشخیص دهند. این روش، عملکرد پایداری در شناسایی دو نوع حمله هم‌زمان ارائه می‌دهد، اما نیاز به توان پردازشی بالا، فضای ذخیره‌سازی بیشتر و تنظیم دقیق پارامترهای یادگیری، کاربردپذیری آن را در محیط‌های واقعی محدود می‌کند [۲۴].

مان^۳ و همکاران در سال ۲۰۲۱ الگوریتمی مبتنی بر درخت تصمیم‌گیری تقویت‌شده گرادیانی^۴ (GBDT) برای تشخیص حملات آلودگی کَش در ICN ارائه کرده‌اند. در این روش، ویژگی‌های آماری و مسیریابی استخراج‌شده برای آموزش مدل استفاده می‌شوند تا رفتار غیرعادی در ترافیک شبکه تشخیص داده شود. نتایج آزمایش‌های مقایسه‌ای نشان داد که GBDT از نظر دقت تشخیص برتری قابل‌توجهی نسبت به روش‌های آستانه‌محور دارد. با این وجود، پیچیدگی محاسباتی بالا و نیاز به داده‌های آموزشی با کیفیت، پیاده‌سازی این روش را در گره‌های سبک‌وزن یا با منابع محدود دشوار می‌کند [۲۵].

یائو و همکاران^۵ در (۲۰۲۰) روشی مبتنی بر پیش‌بینی محبوبیت با استفاده از مدل خاکستری پیشنهاد داده‌اند که با تحلیل روندهای تاریخی رفتار درخواست‌ها و برآورد سه شاخص اصلی—الگوی درخواست گذشته، محبوبیت لحظه‌ای و پیش‌بینی آینده محبوبیت—انحرافات غیرعادی در رفتار ترافیکی را شناسایی می‌کند. در صورت تشخیص اختلاف مکرر بین محبوبیت پیش‌بینی‌شده و واقعی، حمله شناسایی و سیاست دفاعی مناسب اعمال می‌شود. مزیت این رویکرد در تفکیک رفتار مشروع ناگهانی از حملات واقعی است، اما وابستگی به دقت مدل پیش‌بینی و نیاز به داده‌های تاریخی معتبر، از محدودیت‌های اجرایی آن محسوب می‌شود [۲۶].

ژائو^۶ همکاران در سال ۲۰۲۰ در چارچوب V-NDN با تقسیم کَش هر گره به دو بخش «پرطرفدار» و «کم‌طرفدار»، محتوای ورودی را بر اساس سطح محبوبیت در محل مناسب ذخیره می‌کنند و در صورت نوسان شدید محبوبیت، محتوا را به لیست نظارتی حمله اضافه می‌کنند. نتایج شبیه‌سازی‌ها نشان می‌دهد که این مکانیزم در مواجهه با حملات فعال تا ۱۴٪ نرخ اصابت کَش را ارتقاء داده و تا ۳۰٪ تأخیر پاسخگویی را کاهش می‌دهد؛ اما مدیریت پیچیده چندبخشی کَش و نیاز به به‌روزرسانی مداوم اطلاعات محبوبیت در محیط‌های پویای VANET می‌تواند منابع گره را تحت فشار قرار دهد [۲۷].

بووانساری^۷ و همکاران در سال ۲۰۲۰ الگوریتمی مبتنی بر شبکه عصبی تابع پایه شعاعی^۸ (RBFNN) ارائه داده‌اند که با دریافت ویژگی‌های ذاتی مرتبط با محتوای کَش شده، نوع حمله را به سه دسته «سالم»، «تخریب موضعی» و «محبوبیت کاذب» طبقه‌بندی می‌کند. نتایج آزمایش‌ها نشان داد که RBFNN در شناسایی نوع حمله دقت بالایی دارد و از نظر کارایی نسبت به برخی روش‌های مرسوم عملکرد بهتری ارائه می‌دهد. با این حال، نیاز به تنظیم دقیق پارامترها، طراحی مؤثر تابع فعال‌سازی و مدیریت سربار پردازشی در گره‌های لبه با محدودیت منابع، از چالش‌های اصلی این رویکرد است [۲۸].

نایگون^۹ و همکاران در سال ۲۰۱۹ از طریق مدل تشخیصی مبتنی بر آزمون نسبت درست‌نمایی تعمیم‌یافته و یک آشکارساز ترتیبی، حملات سیل درخواست زیرساختی (IFA) را در پیاده‌سازی‌های واقعی ترکیبی NDN و IP با دقت بالا و بدون تحمیل سربار زیاد شناسایی می‌کنند. این تحقیق نشان می‌دهد که حتی باوجود استفاده از بسته‌های NACK برای کنترل جریان درخواست، مسیرهایی برای اجرای مؤثر حملات باقی می‌ماند. باوجود قابلیت اجراپذیری بالای این روش در محیط‌های ترکیبی NDN/IP، نیاز به توسعه بیشتر برای پوشش تمامی حملات در شبکه‌های صرفاً NDN و بهبود واکنش بلادرنگ وجود دارد [۲۹].

¹ Liu and Peng

² Improved Collusive Interest Flooding Attacks

³ Man

⁴ Gradient boost decision tree

⁵ Yao

⁶ Zhou

⁷ Buhanesvari

⁸ Radial Basis Function Neural Network

⁹ Nguyen

سبا^۱ و همکاران در سال ۲۰۱۹ چهار سناریوی تهدید ناشی از گره های فرصت طلب تأمین کننده محتوای جعلی^۲ (FCPs) را در شبکه های موبایل فرصت طلب^۳ (OMN) تعریف کرده و با روش های بلک لیست دائمی یا موقتی، ارتباط با گره های مشکوک را مسدود می کنند. شبیه سازی ها نشان داد که در حضور ۴۰٪ FCP، نرخ پاسخ دهی کاربران قانونی تا ۴۰٪ کاهش یافته و تأخیر تا ۱۷۶٪ افزایش پیدا می کند؛ اما با اعمال روش های پیشنهادی تأخیر تا ۳۶٪ کاهش و نرخ پاسخ موفق تا ۹٪ افزایش می یابد. هرچند رویکرد بلک لیست مزایای قابل توجهی دارد، اما در مواجهه با تهدیدات پیچیده تر فرصت طلب ناکافی به نظر می رسد [۳۰].

باغ^۴ و همکاران در سال ۲۰۱۸ در پایان نامه دکترای خود سه الگوریتم PFP، PFP-DA و PFP-β را معرفی و ارزیابی کرده اند. در الگوریتم PFP، محبوبیت محتوا بر اساس سهم هر Face محاسبه و نرمال سازی می شود تا از تمرکز مصنوعی محبوبیت جلوگیری گردد. نسخه PFP-DA با افزودن مکانیزم کهنگی پویا به داده هایی که صرفاً تاریخی محبوب بوده اما اکنون کم استفاده هستند اجازه می دهد تدریجاً حذف شوند، و نسخه PFP-β با پارامتر β توزیع محبوبیت را مطابق با Zipf شبیه سازی می کند. نتایج تجربی نشان داده اند که PFP-DA و PFP-β نسبت به LRU و LFU-DA در هر دو شرایط عادی و مواجهه با حملات آلودگی کش عملکرد برتری دارند. اما اجرای این الگوریتم ها مستلزم محاسبات بلادرنگ و نگهداری اطلاعات انتشار در هر Face است که در گره های با منابع محدود به معارضاتی از نظر مصرف حافظه و پردازش می انجامد [۳۱].

در بررسی روش های مقابله با حملات کش در معماری NDN می توان به موارد زیر اشاره کرد: اولاً، روش های مبتنی بر یادگیری ماشین، یادگیری تقویتی و تحلیل رفتاری پیشرفته دقت تشخیص بالایی دارند و می توانند الگوهای پیچیده ترافیک و رفتارهای غیرعادی را در محیط های پویا به خوبی شناسایی کنند. ثانیاً، مدل سازی رفتار کاربران، خوشه بندی داده ها و تحلیل مسیرهای محتوا توانسته است در برابر حملات چندوجهی و جعل محبوبیت عملکرد مؤثری ارائه دهد، اما این رویکردها به منابع پردازشی بالا و نگهداری ساختارهای داده سنگین نیاز دارند که اجرای آن ها در گره های مرزی یا سبک وزن دشوار است. ثالثاً، الگوریتم های تطبیق پذیر، نظیر روش های پیش بینی محبوبیت و تحلیل توزیع Zipf یا یادگیری تقویتی، توانایی نسبی بالایی در مواجهه با تغییرات سریع ترافیکی و حملات لحظه ای دارند؛ با این حال، آن ها معمولاً به داده های آموزشی دقیق و زمان آموزش قابل توجهی نیازمندند که در محیط های واقعی محدودیت ایجاد می کند. در مقابل، روش های سبک وزن با ساختار ساده و قابلیت اجرا به صورت بلادرنگ، مناسب تر برای کاربرد در شبکه های زنده، گره های لبه و محیط های IoT یا VANET دارند؛ هرچند دقت آن ها معمولاً کمتر از مدل های پیشرفته است. در نهایت، انتخاب بهینه بین این رویکردها بستگی به محدودیت های منابع، نیاز به واکنش سریع و اهمیت دقت تشخیص در هر محیط عملیاتی دارد و توازن میان دقت، تطبیق پذیری و سادگی پیاده سازی، اساس طراحی سامانه ای مقاوم در برابر حملات کش خواهد بود.

جدول ۱: مقایسه ای روش های مقابله با حملات کش در NDN

Table 1: comparison of methods to deal with cache attacks in NDN

سادگی پیاده سازی	تحلیل بلادرنگ	نیاز به آموزش	مقیاس پذیری	مربوطی	تطبیق پذیری	مقاومت در برابر حمله	دقت تشخیص	روش پیشنهادی	شماره مرجع
▲	◀	×	▲	×	▲	▲	◀	محبوبیت + تازگی	[۱۹]
×	◀	×	×	×	◀	◀	◀	HPR-DS	[۲۰]

¹ Saha

² Fake Content Providers

³ Opportunistic Mobile Networks

⁴ Baugh

β	PFP-DA/ β	«	«	«	▶	«	×	«	▶
---------	-----------------	---	---	---	---	---	---	---	---

۳-روش پیشنهادی

در این بخش، رویکردی نوین برای تنظیم تطبیقی پارامتر β در الگوریتم PFP- β -DA ارائه می‌شود. پارامتر β نقش کلیدی در کنترل حساسیت الگوریتم نسبت به رفتار تقاضا در شبکه داده‌های نام‌گذاری شده (NDN) دارد؛ به گونه‌ای که مقادیر کوچک‌تر β موجب افزایش نرخ اصابت گش و کاهش آلودگی می‌شود، در حالی که مقادیر بزرگ‌تر β می‌تواند به ذخیره‌سازی داده‌های غیرمحبوب منجر شود. نسخه اصلاح‌شده PFP- β -DA با بهبود فرمول محبوبیت، سهم درخواست‌ها را بین چهره‌های مختلف محتوا متعادل می‌کند و بدین ترتیب، محتوایی که از چند مسیر معتبر درخواست شده باشد، در گش حفظ می‌شود و داده‌هایی که صرفاً از یک مسیر خاص تقاضا شده‌اند—حتی اگر ظاهراً پرتقاضا باشند—به راحتی گش نمی‌شوند. این رویکرد منجر به افزایش دقت، کاهش آلودگی و بهبود عملکرد گش در مواجهه با حملات می‌گردد. فرمول (۱) برای رتبه‌بندی درخواست‌های هر چهره‌ی محتوا و تعیین محبوبیت کلی آن درخواست‌ها در این روش استفاده می‌شود:

$$P(C, \beta) = \sum_{i=1}^n \frac{1}{r_i^\beta} \quad (1)$$

$$-\infty \leq \beta \leq +\infty$$

این فرمول محبوبیت کلی درخواست محتوای C را با در نظر گرفتن درخواست‌های هر دسته از محتوا C و استفاده از رتبه‌ی (r_i) محتوای C در هر Face (i) محاسبه می‌کند. پارامتر (r_i) نشان‌دهنده رتبه محتوای درخواست شده C در فهرست رتبه‌بندی محبوبیت (i) Face است. در این بخش، با توجه به ناکارآمدی مقدار ثابت β در شرایط پویا و متغیر شبکه NDN، یک رویکرد تطبیقی برای تنظیم خودکار β ارائه می‌شود. برای این منظور، ابتدا مسئله بهینه‌سازی β مدل‌سازی شده و سپس با استفاده از روش ADMM، راهکاری جهت تنظیم لحظه‌ای و تطبیقی این پارامتر پیشنهاد شده است. این راهکار منجر به افزایش انعطاف‌پذیری و دقت الگوریتم گش در برابر تغییرات ترافیکی و حملات خواهد شد.

۳-۱-تعریف مسئله بهینه سازی ADMM

در این بخش، مسئله بهینه‌سازی تنظیم مقدار β به عنوان یک مسئله بهینه‌سازی پارامتری مدل‌سازی خواهد شد. در این مدل، دو معیار اصلی شبکه‌های داده‌های نام‌گذاری شده (NDN)، یعنی نرخ اصابت^۱ و درصد آلودگی گش^۲، به عنوان توابعی از β در نظر گرفته می‌شوند. مقدار β به گونه‌ای تنظیم خواهد شد که نرخ اصابت بیشینه و درصد آلودگی کمینه شود. مدل مسئله به صورت زیر در نظر گرفته می‌شود:

$$\min_{\beta} (-HitRate(\beta) + \lambda \cdot PollutionRate(\beta) + \frac{\rho}{2} (\beta - z + u)^2) \quad (2)$$

$$\text{Subject to } 0 < \beta < 1$$

که در رابطه بالا β به عنوان متغیر تصمیم^۳ شناخته می‌شود و در بازه $[0, 1]$ تعریف شده است. $HitRate(\beta)$ به عنوان تابع نرخ اصابت گش تعریف خواهد شد. $PollutionRate(\beta)$ به عنوان تابع درصد آلودگی گش در نظر گرفته خواهد شد. λ به عنوان پارامتر وزن‌دهی برای کنترل اهمیت نسبی آلودگی در مقابل نرخ اصابت تعریف خواهد شد. پارامتر وزنی که اهمیت کاهش آلودگی گش^۴ را نسبت به افزایش نرخ اصابت گش تعیین می‌کند. $\rho > 0$ پارامتر جریمه در ADMM که سرعت و پایداری همگرایی الگوریتم را کنترل می‌کند. Z متغیر کمکی در ADMM که حل مسئله را به زیر مسئله‌های ساده‌تر تقسیم می‌کند. u متغیر دوگان (ضریب لاگرانژ) که هماهنگی بین به روزرسانی‌های β و z را تضمین می‌کند. در الگوریتم ADMM (الگوریتم ضرب

¹ Hit Rate

² Pollution Rate

³ Decision Variable

⁴ PollutionRate

و اضافه‌سازی)، هدف اصلی تقسیم مسئله پیچیده به زیر مسئله‌های ساده‌تر است تا فرایند بهینه‌سازی را تسهیل کند. در این الگوریتم، سه مرحله اصلی به‌روزرسانی وجود دارد که هر یک از آن‌ها نقش خاصی در فرایند بهینه‌سازی دارند.

در **مرحله اول**، به‌روزرسانی β ، تلاش می‌شود بهترین مقدار β که منجر به بهبود نرخ اصابت و کاهش درصد آلودگی کش می‌شود، پیدا شود. در این مرحله، هدف بهینه‌سازی معادله (۲-۴) است که β را به‌گونه‌ای تنظیم می‌کند که هر دو معیار HitRate و PollutionRate در کنار هم بهینه شوند.

در **مرحله دوم**، به‌روزرسانی متغیر کمکی z انجام می‌شود. این مرحله تضمین می‌کند که مقدار β همواره در بازه $[0, 1]$ باقی بماند و از محدوده مجاز خارج نشود. برای این منظور، از پروجکشن^۱ استفاده می‌شود تا هرگونه تغییر در β به‌گونه‌ای باشد که همچنان در محدوده مطلوب قرار گیرد.

در **مرحله سوم**، متغیر دوگان u به‌روزرسانی می‌شود تا هماهنگی بیشتری بین به‌روزرسانی‌های β و z حاصل شود. به طور خاص، u نقش یک عامل هماهنگ‌کننده را ایفا می‌کند و تغییرات β و z را به طور مؤثر کنترل می‌کند تا الگوریتم به‌صورت همگرایانه عمل کند. در نهایت، با انجام تکرارهای مکرر و بررسی شرایط همگرایی) با استفاده از ϵ_1 و ϵ_2 برای β و z ، الگوریتم به سمت بهینه‌ترین نقطه همگرا می‌شود. در این فرایند، تنظیم تطبیقی β که توسط ADMM انجام می‌شود موجب می‌شود که به‌طور مستمر به بهترین عملکرد در شرایط متغیر شبکه دست یابد. این فرایند بهینه‌سازی تطبیقی به‌طور خاص در شبکه‌های داده‌های نام‌گذاری شده (NDN) مفید است زیرا شرایط و نیازهای شبکه ممکن است تغییر کند و نیاز به تنظیم بهینه β برای رسیدن به عملکرد بهتر وجود داشته باشد. به صورت خلاصه:

- در هر تکرار، الگوریتم مسئله را به زیر مسئله‌های ساده‌تر تقسیم می‌کند.
- β -update تلاش می‌کند بهترین β را برای بهبود HitRate و PollutionRate پیدا کند.
- z -update تضمین می‌کند β در بازه $[0, 1]$ باقی بماند.
- u -update هماهنگی بین β و z را افزایش می‌دهد.
- در نهایت، β به‌صورت تطبیقی تنظیم می‌شود تا بهترین عملکرد را در شرایط متغیر شبکه حفظ کند. شبه‌کد مربوط به این روش در شکل ۱ به‌طور دقیق توضیح داده خواهد شد.

Initialize:

- Set initial values for $\beta, z, u, \rho, \lambda$
- Set convergence thresholds ϵ_1, ϵ_2
- Set maximum number of iterations MaxIter
- Set initial values for $\text{HitRate}(\beta)$ and $\text{PollutionRate}(\beta)$

For $k = 0$ to MaxIter :

1. Update β using the minimization formula:

$$\beta^{(k+1)} \leftarrow \arg \min_{\beta} \left(-\text{HitRate}(\beta) + \lambda \cdot \text{PollutionRate}(\beta) + \frac{\rho}{2} (\beta - z^{(k)} + u^{(k)})^2 \right)$$

Subject to $0 < \beta < 1$

2. Update z using the projection operator:

$$z^{(k+1)} \leftarrow \text{Projection}_{[0, 1]}(\beta^{(k+1)} + u^{(k)})$$

3. Update dual variable u :

$$u^{(k+1)} \leftarrow u^{(k+1)} + (\beta^{(k+1)} + z^{(k+1)})$$

4. Check for convergence:

If

$$|\beta^{(k+1)} - \beta^{(k)}| < \epsilon_1 \text{ and } |z^{(k+1)} - z^{(k)}| < \epsilon_2$$

Break (converged)

End for

Return $\beta^{(k+1)}, z^{(k+1)}, u^{(k+1)}$

شکل ۱: الگوریتم ADMM در بهبود حافظه نهان

Figure 1: ADMM algorithm in cache memory improvement

¹ Projection

۳-۲-۲-۳ ADMM بهبود یافته

در این بخش، برای ارتقای عملکرد الگوریتم ADMM در بهینه سازی تطبیقی پارامتر β ، روشی برای تنظیم خودکار دو پارامتر کلیدی یعنی ρ و λ معرفی می شود. پارامتر ρ به عنوان عامل جریمه در ADMM، نقش مهمی در تسریع همگرایی و تضمین پایداری الگوریتم دارد. تنظیم نامناسب آن ممکن است منجر به واگرایی یا کندی شدید در همگرایی شود. از این رو، استفاده از روش های تطبیقی برای تنظیم دینامیک ρ در طول تکرارهای الگوریتم، به ویژه از طریق روش های خطی یا غیرخطی، پیشنهاد می شود تا فرایند بهینه سازی با سرعت و دقت بیشتر انجام گیرد.

در کنار آن، پارامتر λ مسئول ایجاد تعادل میان دو هدف متضاد یعنی افزایش نرخ اصابت گش و کاهش آلودگی آن است. تنظیم دقیق λ در محیط های پویا ضروری است تا سیستم بتواند به طور هم زمان به هر دو هدف پاسخ دهد. در این راستا، روش های بهینه سازی تطبیقی برای تنظیم لحظه ای λ نیز پیشنهاد می شود، تا تأثیر آن در هر گام از الگوریتم بر عملکرد کلی مدل بهینه شود. پارامتر ρ در روش ADMM به عنوان پارامتر جریمه نقش بسیار مهمی در همگرایی الگوریتم دارد. برای تنظیم خودکار ρ در طول فرایند بهینه سازی، می توان از یک قانون تطبیقی استفاده کرد. یکی از روش های معمول برای این کار، استفاده از قانون خطی یا غیرخطی برای تنظیم ρ بر اساس میزان تغییرات در متغیرهای β و z است. به روزرسانی ρ به صورت تطبیقی به صورت رابطه زیر است:

$$\rho^{(k+1)} = \rho^{(k)} \cdot \left(1 + \alpha \cdot \frac{|\beta^{(k+1)} - \beta^{(k)}|}{\max(|z^{(k+1)} - z^{(k)}|, \varepsilon)}\right) \quad (3)$$

که این رابطه $\rho^{(k)}$ مقدار فعلی پارامتر جریمه است. $\rho^{(k+1)}$ مقدار جدید پارامتر جریمه پس از به روزرسانی است. α یک ضریب ثابت برای کنترل سرعت تغییر ρ است. $|\beta^{(k+1)} - \beta^{(k)}|$ تغییرات در متغیر β در تکرارهای مختلف است. $|z^{(k+1)} - z^{(k)}|$ تغییرات در متغیر z در تکرارهای مختلف است. این فرمول باعث می شود که پارامتر ρ به طور خودکار و بر اساس میزان تغییرات در β و z تنظیم شود. افزایش ρ در صورتی که تغییرات در β و z زیاد باشد، همگرایی را تسریع می کند، در حالی که کاهش ρ زمانی که تغییرات کم باشد، از انحرافات بزرگ جلوگیری می کند. ε یک مقدار کوچک بزرگتر از صفر است. مقدار ε معمولاً عددی بسیار کوچک است که به طور خودکار تنظیم می شود تا از آسیب به فرایند همگرایی جلوگیری کند.

• تنظیم پارامتر λ به صورت تطبیقی

برای تنظیم خودکار پارامتر λ که تأثیر زیادی در تعادل میان نرخ اصابت و آلودگی گش دارد، می توان از یک روش مشابه برای تنظیم آن استفاده کرد. در اینجا، پیشنهاد می شود که λ بر اساس تغییرات در نرخ اصابت و درصد آلودگی گش به طور خودکار به روزرسانی شود. فرمول پیشنهادی برای به روزرسانی λ به صورت تطبیقی به صورت زیر است:

$$\lambda^{(k+1)} = \lambda^{(k)} \cdot \left(1 + \beta_\lambda \cdot \frac{|HitRate(\beta^{(k+1)}) - HitRate(\beta^{(k)})|}{\max(|PollutionRate(\beta^{(k+1)}) - PollutionRate(\beta^{(k)})|, \varepsilon)}\right) \quad (4)$$

که در آن $\lambda^{(k)}$ مقدار فعلی پارامتر λ است. $\lambda^{(k+1)}$ مقدار جدید پارامتر λ پس از به روزرسانی است. β_λ یک ضریب ثابت برای کنترل سرعت تغییر λ است. $|HitRate(\beta^{(k+1)}) - HitRate(\beta^{(k)})|$ تغییرات در نرخ اصابت است. $\max(|PollutionRate(\beta^{(k+1)}) - PollutionRate(\beta^{(k)})|, \varepsilon)$ بیشترین تغییرات در درصد آلودگی گش است. در اینجا، λ با توجه به تغییرات در نرخ اصابت و آلودگی گش تنظیم می شود. اگر تفاوت های زیادی در نرخ اصابت و آلودگی گش مشاهده شود، λ به طور تطبیقی افزایش می یابد تا تعادل بهتری بین این دو معیار برقرار شود.

استفاده از $\max$ در مخرج، هدف اصلی جلوگیری از تقسیم بر صفر و همچنین بهینه سازی فرایند به روزرسانی پارامتر λ است. دلیل استفاده از $\max$ در مخرج این است که در صورت نزدیک بودن تغییرات نرخ اصابت و آلودگی به صفر، این تغییرات معمولاً خیلی کوچک هستند و ممکن است باعث نوسانات زیاد در روند همگرایی شوند. در این رابطه، استفاده از تضمین می کند که هیچ گاه تقسیم بر صفر صورت نخواهد گرفت. به عبارت دیگر، اگر تفاوت های $PollutionRate(\beta^{(k+1)})$ و $PollutionRate(\beta^{(k)})$ بسیار کوچک و نزدیک به صفر باشند، به جای تقسیم بر عدد صفر، مقدار بسیار کوچکی ε در مخرج قرار داده می شود که مانع از تقسیم بر صفر و حفظ پایداری الگوریتم می شود. این امر در نهایت باعث بهینه سازی به طور ایمن و جلوگیری از تغییرات

غیرمنطقی در مقدار λ می‌شود و همگرایی الگوریتم را بهبود می‌بخشد. به‌طور کلی، هدف این است که حتی زمانی که تفاوت‌ها به حداقل ممکن رسیده‌اند، الگوریتم به‌طور پیوسته و بدون مشکل ادامه یابد.

• فرمول کلی به‌روزرسانی ADMM با پارامترهای تطبیقی ρ و λ

در این تحقیق، برای بهینه‌سازی عملکرد الگوریتم ADMM در حل مسئله بهینه‌سازی β و دستیابی به تعادل میان نرخ اصابت و آلودگی کش، از تنظیم تطبیقی پارامترهای الگوریتم استفاده شده است. تنظیم مناسب پارامترهای ρ و λ نقش اساسی در تسریع همگرایی و بهبود دقت الگوریتم ایفا می‌کند. با بهره‌گیری از این رویکرد تطبیقی، به‌طور مؤثر تغییرات پارامترها در طول فرایند بهینه‌سازی مدیریت می‌شود که موجب بهبود کیفیت نتایج و کاهش هزینه‌های محاسباتی می‌گردد. این رویکرد علاوه بر اطمینان از همگرایی سریع و پایدار الگوریتم، به مدل این امکان را می‌دهد که در محیط‌های دینامیک و متغیر شبکه‌ها، عملکرد مطلوب خود را حفظ کند. شبکه‌کد روش پیشنهادی در الگوریتم شکل ۲ ارائه شده است. در آغاز اجرای الگوریتم، مقادیر اولیه متغیرهای اصلی شامل β متغیر تصمیم برای بهینه‌سازی نرخ اصابت و کاهش آلودگی، z متغیر کمکی برای ساده‌سازی و هماهنگی، u متغیر دوگان برای تضمین همگرایی، و پارامترهای ρ و λ به‌ترتیب برای کنترل جریمه و تعادل بین نرخ اصابت و آلودگی (تعیین می‌شوند. همچنین، آستانه‌هایی برای همگرایی مشخص می‌شود تا الگوریتم در صورت رسیدن به شرایط مطلوب متوقف گردد.

مرحله ۱: به‌روزرسانی β

در این مرحله، متغیر β به‌گونه‌ای به‌روزرسانی می‌شود که بهترین نتیجه را در زمینه بهبود نرخ اصابت و کاهش آلودگی کش به دست آورد. هدف این است که β به‌گونه‌ای تنظیم شود که هر دو معیار بهینه شوند. این مرحله به‌طور کلی به حل یک مسئله بهینه‌سازی می‌پردازد که نیاز به استفاده از روش‌های بهینه‌سازی دارد.

$$\beta^{(k+1)} \leftarrow \arg \min_{\beta} (-HitRate(\beta) + \lambda^{(k)} \cdot PollutionRate(\beta) + \frac{\rho^{(k)}}{2} (\beta - z^{(k)} + u^{(k)})^2) \quad (5)$$

مرحله ۲: به‌روزرسانی متغیر کمکی z

در این مرحله، مقدار متغیر کمکی z به‌روزرسانی می‌شود تا همیشه در بازه معین قرار داشته باشد (در اینجا بازه $[0, 1]$). برای این منظور، عملگر projection به‌کار می‌رود تا اطمینان حاصل شود که مقدار z از این بازه خارج نمی‌شود.

$$z^{(k+1)} \leftarrow \text{Projection}_{[0, 1]}(\beta^{(k+1)} + u^{(k)}) \quad (6)$$

مرحله ۳: به‌روزرسانی متغیر دوگان u

در این مرحله، متغیر دوگان u به‌روزرسانی می‌شود. این به‌روزرسانی برای همسان‌سازی و هماهنگی بین β و z است. وقتی β و z به‌طور مستقل به‌روزرسانی می‌شوند، متغیر u اختلافات میان این دو را اصلاح کرده و به‌روزرسانی‌های بعدی را هماهنگ می‌کند.

$$u^{(k+1)} \leftarrow u^{(k+1)} + (\beta^{(k+1)} + z^{(k+1)}) \quad (7)$$

مرحله ۴: به‌روزرسانی پارامتر ρ به‌صورت تطبیقی

در این مرحله، پارامتر ρ که به‌عنوان پارامتر جریمه در الگوریتم استفاده می‌شود، به‌طور تطبیقی تغییر می‌کند. اگر تغییرات در β یا z زیاد باشد، ρ افزایش می‌یابد تا همگرایی سریع‌تر شود. در صورت تغییرات کم، ρ کاهش می‌یابد تا از تغییرات غیرضروری جلوگیری شود.

$$\rho^{(k+1)} = \rho^{(k)} \cdot (1 + \alpha \cdot \frac{|\beta^{(k+1)} - \beta^{(k)}|}{\max(|z^{(k+1)} - z^{(k)}|, \epsilon)}) \quad (8)$$

مرحله ۵: به‌روزرسانی پارامتر λ به‌صورت تطبیقی

در این مرحله، پارامتر λ که مسئول تنظیم تعادل بین نرخ اصابت و آلودگی کش است، به‌طور تطبیقی تنظیم می‌شود. اگر تغییرات در نرخ اصابت زیاد باشد، λ افزایش می‌یابد تا اهمیت این معیار بیشتر شود. اگر تغییرات در آلودگی کش بیشتر باشد، λ به‌گونه‌ای تنظیم می‌شود که تأثیر بیشتری در کاهش آلودگی داشته باشد.

$$\lambda^{(k+1)} = \lambda^{(k)} \cdot (1 + \beta_\lambda \cdot \frac{|HitRate(\beta^{(k+1)}) - HitRate(\beta^{(k)})|}{\max(|PollutionRate(\beta^{(k+1)}) - PollutionRate(\beta^{(k)})|, \epsilon)}) \quad (9)$$

مرحله ۶: همگرایی و توقف الگوریتم

الگوریتم با بررسی تغییرات در β و z به دنبال همگرایی می گردد. اگر تغییرات در هر دو متغیر از حد معینی کوچک تر شود، الگوریتم متوقف می شود. این تضمین می کند که الگوریتم به حالت بهینه خود رسیده است.

$$if |\beta^{(k+1)} - \beta^{(k)}| < \epsilon_1 \text{ and } |z^{(k+1)} - z^{(k)}| < \epsilon_2 \text{ then stop} \quad (10)$$

در نهایت، پس از انجام تمام مراحل و به روزرسانی متغیرها، مقدار نهایی β ، z ، λ و ρ به دست می آید که این مقادیر برای بهینه سازی سیستم در شرایط دینامیک و متغیر شبکه به کار می روند. تنظیم تطبیقی این پارامترها باعث تسریع همگرایی، بهبود عملکرد و کاهش هزینه های محاسباتی در الگوریتم می شود.

Initialize:

- Set initial values for β , z , u , ρ , λ
- Set convergence thresholds ϵ_1 , ϵ_2
- Set constants α , β_λ
- Set maximum number of iterations MaxIter
- Set initial values for HitRate(β) and PollutionRate(β)

For $k = 0$ to MaxIter:

1. Update β using the minimization formula:

$$\beta^{(k+1)} \leftarrow \arg \min_{\beta} (-HitRate(\beta) + \lambda^{(k)} \cdot PollutionRate(\beta) + \frac{\rho^{(k)}}{2} (\beta - z^{(k)} + u^{(k)})^2)$$

Apply optimization method to minimize the objective function

2. Update z using the projection operator:

$$z^{(k+1)} \leftarrow \text{Projection}_{[0,1]}(\beta^{(k+1)} + u^{(k)})$$

Ensure that z stays within the range $[0, 1]$

3. Update dual variable u :

$$u^{(k+1)} \leftarrow u^{(k+1)} + (\beta^{(k+1)} + z^{(k+1)})$$

Adjust dual variable to enforce the consistency between β and z

4. Update ρ adaptively:

$$\Delta\beta \leftarrow |\beta^{(k+1)} - \beta^{(k)}| \quad \Delta\beta \leftarrow |\beta^{(k+1)} - \beta^{(k)}|$$

$$\Delta z \leftarrow |z^{(k+1)} - z^{(k)}| \quad \Delta z \leftarrow |z^{(k+1)} - z^{(k)}|$$

$$\rho^{(k+1)} \leftarrow \rho^{(k)} \cdot (1 + \alpha \cdot \frac{\Delta\beta}{\max(\Delta z, \epsilon)})$$

Adjust the penalty parameter ρ based on changes in β and z

5. Update λ adaptively:

$$\Delta HitRate \leftarrow |HitRate(\beta^{(k+1)}) - HitRate(\beta^{(k)})|$$

$$\Delta PollutionRate \leftarrow \max(|PollutionRate(\beta^{(k+1)}) - PollutionRate(\beta^{(k)})|, \epsilon)$$

$$\lambda^{(k+1)} \leftarrow \lambda^{(k)} \cdot (1 + \beta_\lambda \cdot \frac{\Delta HitRate}{\Delta PollutionRate})$$

Adjust λ based on the change in the hit rate and pollution rate

6. Check for convergence:

if

$$|\beta^{(k+1)} - \beta^{(k)}| < \epsilon_1 \text{ and } |z^{(k+1)} - z^{(k)}| < \epsilon_2$$

Break (converged)

If both β and z have converged, stop the algorithm

End for

Return $\beta^{(k+1)}$, $z^{(k+1)}$, $\lambda^{(k+1)}$, $\rho^{(k+1)}$

شکل ۲: الگوریتم شبه کد پیشنهادی ADMM بهبود یافته

Figure 2: The pseudo-code algorithm of the proposed improved ADMM

۴-نتایج

در این پژوهش، برای انجام شبیه سازی ها و تحلیل ها، از ترکیب دو ابزار مکمل استفاده شده است تا هم جنبه های تحلیلی و عددی و هم ارزیابی های شبکه ای به صورت دقیق پوشش داده شود. پیاده سازی الگوریتم پیشنهادی و تحلیل رفتار بهینه سازی

پارامتر β در محیط MATLAB 2020Rb انجام شده است؛ این محیط بادقت بالا و توان محاسباتی مناسب، امکان تحلیل همگرایی، تنظیم پارامترها و بررسی عددی مدل را فراهم کرده است. در ادامه، برای ارزیابی عملکرد الگوریتم در سناریوهای واقعی شبکه‌های NDN، از شبیه‌ساز تخصصی ndnSIM، مبتنی بر NS-3، بهره گرفته شد. این ابزار امکان شبیه‌سازی دقیق تعامل گره‌ها، حافظه نهان و شرایط حمله را فراهم می‌کند. سخت‌افزار مورد استفاده شامل پردازنده Intel Core i7 با فرکانس ۲.۶۰ گیگاهرتز و ۸ گیگابایت رم تحت سیستم عامل Windows 10 بوده است. این ترکیب ابزاری، توازن مؤثری میان تحلیل عددی دقیق و ارزیابی عملیاتی الگوریتم در محیط شبکه‌ای ایجاد کرده است.

۴-۱- معیارهای ارزیابی

در این پژوهش، برای ارزیابی عملکرد روش پیشنهادی، دو معیار اصلی به کار گرفته شده‌اند که نقش کلیدی در تحلیل و مقایسه الگوریتم‌ها دارند. اولین معیار، نرخ اصابت حافظه نهان^۱ (CHR)، نشان‌دهنده درصد درخواست‌های پاسخ داده شده مستقیماً از کش است و معیار اساسی برای سنجش کارایی سیستم کش محسوب می‌شود؛ چرا که افزایش این نرخ منجر به کاهش تأخیر در تحویل محتوا و بهبود تجربه کاربر می‌شود.

$$CHR\% = \frac{\text{Number of cache hits}}{\text{Total number of content requests}} \times 100 \quad (11)$$

در این رابطه Number of cache hits تعداد درخواست‌هایی که از حافظه نهان پاسخ داده شده‌اند (تعداد اصابت‌ها به کش) و Total number of content requests تعداد کل درخواست‌های محتوای کاربران (صرف‌نظر از اینکه از کش پاسخ داده شده‌اند یا نه) است.

دومین معیار، درصد آلودگی حافظه نهان^۲ (CPR)، شاخصی مهم در شناسایی و کاهش محتوای غیرمفید و حملات آلودگی کش است و بیانگر توانایی الگوریتم در حفظ کیفیت داده‌های ذخیره شده است.

$$CPR\% = \frac{\text{Number of polluted contents in the cache}}{\text{Total number of cached contents}} \times 100 \quad (12)$$

در این رابطه Number of polluted contents in the cache تعداد داده‌های آلوده یا غیرمحبوب موجود در حافظه نهان و Total number of cached contents تعداد کل داده‌هایی که در حافظه نهان ذخیره شده‌اند.

۴-۲- توپولوژی‌ها و سناریوها


در این پژوهش، چهار نوع توپولوژی شبکه شامل سلسله‌مراتبی، ساده، پیشرفته و مش (شکل ۳) طراحی شده‌اند تا عملکرد الگوریتم پیشنهادی به‌ویژه الگوریتم ADMM و نسخه بهبود یافته آن ارزیابی شود. در توپولوژی سلسله‌مراتبی در شکل ۳a، شبکه شامل سه لایه است: لایه اول که گره‌های تولیدکننده محتوا را در بر می‌گیرد، لایه دوم که گره‌های میانی با حافظه‌های نهان هستند، و لایه سوم که گره‌های مصرف‌کننده در آن قرار دارند. در این توپولوژی، سه سناریو طراحی شده است: سناریوی اول شبکه پایدار است که به بررسی تأثیر ظرفیت کش در سه مقدار مختلف می‌پردازد. سناریوی دوم به بررسی تاب‌آوری الگوریتم در برابر حملات آلودگی کش (CPA) با افزایش تعداد درخواست‌های مخرب پرداخته است. در نهایت، سناریوی سوم تغییرات بار ترافیکی را مورد بررسی قرار می‌دهد که در آن نرخ درخواست‌ها به‌طور دینامیک از ۵ به ۲۰ درخواست در ثانیه تغییر می‌کند. در توپولوژی ساده در شکل b، شبکه شامل سه لایه است: گره‌های تولیدکننده، مصرف‌کننده و میانه با حافظه نهان. در این توپولوژی نیز سه سناریو طراحی شده است: سناریوی شبکه پایدار که عملکرد الگوریتم در شرایط عادی بررسی می‌شود، حمله آلودگی کش که شبیه‌سازی حملات با درخواست‌های جعلی را شامل می‌شود، و تغییرات بار ترافیکی که به بررسی توانایی الگوریتم در مقابله با تغییرات پویا در تعداد کاربران و نرخ درخواست‌ها می‌پردازد.

در توپولوژی پیشرفته در شکل c، ساختار پیچیده‌تری از سلسله‌مراتب با به‌روزرسانی پارامترهای الگوریتم ADMM در گره‌های میانی به‌صورت توزیع شده طراحی شده است. سه سناریو در این توپولوژی به شرح زیر است: در شبکه پایدار، عملکرد الگوریتم در شرایط بدون حمله ارزیابی می‌شود. در حمله آلودگی کش (CPA)، مقاومت الگوریتم در برابر حملات آلودگی کش بررسی می‌شود و در تغییرات بار ترافیکی (پویا)، توانایی الگوریتم در پاسخ به تغییرات دینامیکی بار ترافیکی ارزیابی می‌شود.

¹ Cache Hit Rate

² Cache Pollution Rate

در توپولوژی مش در شکل d، گره ها به صورت غیرمتمرکز و با اتصالات چندگانه با یکدیگر در ارتباط هستند. در این توپولوژی، سه سناریو تعریف شده است: ازدحام موضعی و مسیرهای غیرتعالی که به بررسی توانایی الگوریتم در مدیریت ترافیک غیر متعادل می پردازد، قطع برخی لینک ها که ارزیابی پایداری و تاب آوری الگوریتم در برابر خرابی های شبکه را شامل می شود، و حمله هدفمند توزیع شده که به بررسی مقاومت الگوریتم در برابر حملات توزیع شده آلودگی کش می پردازد.



شکل ۳: توپولوژی های بررسی شده

Figure 3: Topologies examined

این توپولوژی ها و سناریوها به طور جامع توانایی الگوریتم های پیشنهادی را در شرایط مختلف شبکه ای، از جمله حملات و تغییرات ترافیکی، ارزیابی می کنند. در ادامه جدول ۲ جامع برای توپولوژی ها و سناریوهای مختلف شبیه سازی شده در این پژوهش آورده شده است.

جدول ۲: بررسی جامع توپولوژی ها و سناریوهای مختلف شبیه سازی شده

Table 2: comprehensive review of different simulated topologies and scenarios

توپولوژی شبکه	سناریو	هدف ارزیابی	شرح
توپولوژی سلسله مراتبی (شکل a)	شبکه پایدار	ارزیابی حساسیت الگوریتم به ظرفیت حافظه کش و بررسی نرخ اصابت کش و آلودگی کش	بررسی عملکرد الگوریتم در شرایط عادی و بدون حمله، با تنظیم ظرفیت کش در سه مقدار مختلف (۵۰۰، ۱۰۰۰، ۲۰۰۰ محتوا)
	حمله آلودگی کش (CPA)	ارزیابی مقاومت الگوریتم در برابر حملات آلودگی کش و حفظ کیفیت سرویس	بررسی تاب آوری الگوریتم در برابر حملات آلودگی کش با افزایش تدریجی تعداد درخواست های مخرب از ۵ به ۲۰ درخواست در ثانیه
	تغییرات بار ترافیکی (پویا)	سنجش تطبیق پذیری الگوریتم در شرایط متغیر شبکه و حفظ عملکرد بهینه کش	بررسی توانایی الگوریتم در مدیریت تغییرات ناگهانی یا تدریجی در تعداد کاربران و نرخ درخواست ها (از ۵ به ۲۰ درخواست در ثانیه)
توپولوژی ساده (شکل b)	شبکه پایدار	ارزیابی نرخ اصابت کش (CHR) و آلودگی کش (CPR) در شرایط عادی و ثابت بدون حمله	بررسی عملکرد الگوریتم در شرایط پایدار و بدون حمله در شبکه با بار ترافیکی ثابت و نرخ درخواست کاربران مطابق با توزیع Zipf
	حمله آلودگی کش (CPA)	بررسی مقاومت الگوریتم در برابر حملات آلودگی کش و حفظ نرخ اصابت کش و کاهش آلودگی کش	بررسی عملکرد الگوریتم در برابر درخواست های جعلی و غیرمحبوب ارسال شده توسط مهاجمان به حافظه های نهان
	تغییرات بار ترافیکی (پویا)	بررسی توانایی الگوریتم در تطبیق با تغییرات بار ترافیکی و تنظیم خودکار پارامترهای α ، β ، λ	بررسی تغییرات ناگهانی یا تدریجی در تعداد کاربران و نرخ درخواست ها و ارزیابی توانایی الگوریتم در تطبیق خود با شرایط تغییرات بار
توپولوژی پیشرفته	شبکه پایدار	سنجش دقت الگوریتم در شرایط بدون حمله و حفظ نرخ اصابت کش و کاهش آلودگی کش	بررسی عملکرد الگوریتم در محیط بدون حمله با ساختار پیچیده تر و چندلایه (تولید کننده، حافظه های نهان، مصرف کننده)

توپولوژی مش (شکل d)	حمله توزیع‌شده آلودگی کَش	سنجش مقاومت الگوریتم در برابر حملات توزیع‌شده آلودگی کَش و توانایی آن در حفظ کیفیت کَش و بهینه‌سازی محتوا	بررسی عملکرد الگوریتم در برابر حملات هماهنگ و توزیع‌شده که به‌صورت هم‌زمان از مسیرهای مختلف درخواست‌های جعلی و غیرمحبوب به شبکه ارسال می‌شود
	قطع برخی لینک‌ها	ارزیابی انعطاف الگوریتم در شرایط خرابی لینک‌ها و حفظ کیفیت سرویس و تحویل محتوا بدون اختلال	شبیه‌سازی خرابی لینک‌ها و بررسی عملکرد الگوریتم در شرایط قطع یا اختلال لینک‌ها و شناسایی مسیرهای جایگزین برای حفظ عملکرد کَش
	ازدحام موضعی و مسیرهای غیرتعادلی	ارزیابی قدرت الگوریتم در توزیع متوازن بار و حفظ تعادل کَش‌ها و کاهش تأخیر در تحویل محتوا	بررسی بار ترافیکی سنگین در بخش‌های خاص شبکه و ارزیابی توانایی الگوریتم در مدیریت ازدحام و توزیع بار به طور هوشمندانه میان مسیرهای جایگزین
	تغییرات بار ترافیکی (پویا)	سنجش انطباق‌پذیری الگوریتم در برابر تغییرات بار ترافیکی و حفظ عملکرد بهینه در شرایط دینامیک شبکه	بررسی توانایی الگوریتم در مدیریت تغییرات پویا در تعداد کاربران و نرخ درخواست‌ها و ارزیابی قدرت الگوریتم در تطبیق خود با شرایط متغیر شبکه
(شکل c)	حمله آلودگی کَش (CPA)	ارزیابی مقاومت الگوریتم در برابر حملات آلودگی کَش و حفظ کیفیت کَش و بهینه‌سازی پارامترها	بررسی تاب‌آوری الگوریتم در برابر حملات آلودگی کَش با درخواست‌های جعلی و داده‌های غیرمحبوب ارسال‌شده توسط مهاجمان

۴-۳- ارزیابی در توپولوژی سلسله مراتبی

در این پژوهش، عملکرد الگوریتم‌های ADMM و نسخه بهبودیافته آن (ADMM-Enhanced) در سه سناریو مختلف شبکه در توپولوژی سلسله‌مراتبی بررسی شد. در سناریو شبکه پایدار (جدول ۳)، الگوریتم‌های ADMM و ADMM-Enhanced نسبت به روش‌های کلاسیک مانند LFU-DA و LRU عملکرد بهتری داشتند، با نرخ اصابت کَش بالاتر و درصد آلودگی کَش پایین‌تر. در سناریوی حمله آلودگی کَش (جدول ۴)، این الگوریتم‌ها توانستند مقاومت بیشتری در برابر حملات نشان دهند و آلودگی کَش را کاهش داده و نرخ اصابت کَش را حفظ کنند، در حالی که روش‌های کلاسیک آسیب‌پذیرتر بودند. در سناریوی تغییرات بار ترافیکی (جدول ۵)، الگوریتم‌های ADMM و ADMM-Enhanced با توانایی تطبیق‌پذیری بالا، در شرایط پویا عملکرد مطلوبی داشتند و نرخ اصابت کَش را حفظ کرده و آلودگی کَش را کنترل کردند. به طور کلی، این الگوریتم‌ها در تمام سناریوها نسبت به روش‌های مرسوم عملکرد برتری نشان داده‌اند و به‌عنوان یک راهکار مؤثر برای مدیریت حافظه‌های نهان در شبکه‌های داده‌محور پیشنهاد می‌شوند.

جدول ۳: سناریو ۱ توپولوژی سلسله مراتبی: شبکه پایدار (بدون حمله)

Table 3: Hierarchical topology scenario 1: stable network (no attack)

الگوریتم	Top 50 نرخ اصابت	Top 100 نرخ اصابت	CPR (درصد آلودگی کَش)	CHR (نرخ اصابت کَش)
PFP-DA	78.00%	68.00%	10.00%	21.00%
LFU-DA	65.00%	55.00%	20.00%	15.00%
LRU	58.00%	48.00%	25.00%	12.00%
ADMM	80.00%	70.00%	8.00%	23.00%
ADMM-Enhanced	82.00%	72.00%	7.00%	25.00%

جدول ۴: سناریو ۲ توپولوژی سلسله مراتبی: شبکه تحت حمله آلودگی کَش (CPA)

Table 4: Hierarchical Topology Scenario 2: Network Under CPA Attack

الگوریتم	Top 50 نرخ اصابت	Top 100 نرخ اصابت	CPR (درصد آلودگی کَش)	CHR (نرخ اصابت کَش)
PFP-DA	75.53%	62.80%	15.00%	19.02%
LFU-DA	50.00%	41.17%	36.00%	12.67%
LRU	34.64%	28.72%	36.00%	8.82%
ADMM	77.00%	65.00%	12.00%	21.00%
ADMM-Enhanced	80.00%	68.00%	10.00%	23.00%

جدول ۵: سناریو ۳ توپولوژی سلسله مراتبی: تغییرات بار ترافیکی (پویا)

Table 5: scenario 3 of hierarchical topology: traffic load changes (dynamic)

الگوریتم	Top 50 نرخ اصابت	Top 100 نرخ اصابت	CPR (درصد آلودگی کَش)	CHR (نرخ اصابت کَش)
PFP-DA	70.00%	60.00%	14.00%	18.00%
LFU-DA	52.00%	45.00%	28.00%	11.00%
LRU	48.00%	40.00%	30.00%	9.00%

ADMM	20.00%	11.00%	63.00%	75.00%
ADMM-Enhanced	22.00%	9.00%	65.00%	77.00%

۴-۴- نتایج ارزیابی در سناریوهای توپولوژی ساده

در این تحقیق، عملکرد الگوریتم های ADMM و نسخه پیشرفته آن (ADMM-Enhanced) در سه سناریوی مختلف شبکه مورد ارزیابی قرار گرفت. در سناریوی شبکه پایدار (جدول ۶)، الگوریتم های پیشنهادی عملکرد قابل توجهی نسبت به روش های کلاسیک مانند LFU-DA و LRU داشتند. این الگوریتم ها توانستند نرخ اصابت کَش بالاتری داشته باشند و همزمان درصد آلودگی کَش را در سطح پایین تری حفظ کنند. در حالی که روش های دیگر مانند LFU-DA و LRU نرخ اصابت کَش کمتری داشتند و درصد آلودگی کَش در آن ها بالاتر بود. در سناریوی حمله آلودگی کَش (CPA) (جدول ۷)، الگوریتم های ADMM و ADMM-Enhanced مقاومت بهتری نشان دادند و توانستند با وجود حمله، آلودگی کَش را به میزان چشمگیری کاهش دهند و نرخ اصابت کَش را در سطح بالایی حفظ کنند. در مقابل، الگوریتم های کلاسیک مانند LFU-DA و LRU در برابر حملات آسیب پذیر بودند و با افزایش آلودگی کَش و کاهش نرخ اصابت مواجه شدند. در سناریوی تغییرات بار ترافیکی (پویا) (جدول ۸)، الگوریتم های ADMM و ADMM-Enhanced توانایی تطبیق خود با تغییرات پویا در بار ترافیکی را نشان دادند. برخلاف روش های سنتی که در شرایط تغییرات ناگهانی عملکرد ضعیفی داشتند، این الگوریتم ها توانستند نرخ اصابت کَش را حفظ کرده و آلودگی کَش را در سطح مطلوبی کنترل کنند. به طور کلی، نتایج نشان می دهند که الگوریتم های ADMM و ADMM-Enhanced به دلیل استفاده از تنظیم تطبیقی پارامترها، در تمامی سناریوها، از جمله شبکه های پایدار، شرایط تحت حمله و وضعیت های پویا، عملکرد بهتری نسبت به روش های مرسوم دارند.

جدول ۶: سناریو ۱ توپولوژی ساده: شبکه پایدار (بدون حمله)

Table 6: Scenario 1 Simple topology: stable network (no attack)

الگوریتم	نرخ اصابت کَش (CHR)	درصد آلودگی کَش (CPR)	Top 100 نرخ اصابت	Top 50 نرخ اصابت
PFP-DA	20.00%	11.00%	67.00%	77.00%
LFU-DA	13.00%	21.00%	53.00%	63.00%
LRU	10.00%	27.00%	47.00%	57.00%
ADMM	22.00%	9.00%	69.00%	79.00%
ADMM-Enhanced	24.00%	8.00%	71.00%	81.00%

جدول ۷: سناریو ۲ توپولوژی ساده: حمله آلودگی کَش (CPA)

Table 7: Scenario 2 of simple topology: CPA attack

الگوریتم	نرخ اصابت کَش (CHR)	درصد آلودگی کَش (CPR)	Top 100 نرخ اصابت	Top 50 نرخ اصابت
PFP-DA	18.50%	16.00%	61.00%	73.00%
LFU-DA	11.50%	35.00%	40.00%	49.00%
LRU	7.50%	37.00%	27.00%	33.00%
ADMM	20.00%	13.00%	64.00%	75.00%
ADMM-Enhanced	22.00%	11.00%	67.00%	78.00%

جدول ۸: سناریو ۳ توپولوژی ساده: تغییر بار ترافیکی (پویا)

Table 8: scenario 3 simple topology: traffic load change (dynamic)

الگوریتم	نرخ اصابت کَش (CHR)	درصد آلودگی کَش (CPR)	Top 100 نرخ اصابت	Top 50 نرخ اصابت
PFP-DA	17.00%	15.00%	58.00%	68.00%
LFU-DA	10.00%	29.00%	44.00%	50.00%
LRU	8.00%	31.00%	39.00%	46.00%
ADMM	19.00%	12.00%	62.00%	73.00%
ADMM-Enhanced	21.00%	10.00%	65.00%	76.00%

۴-۵- نتایج ارزیابی برای توپولوژی پیشرفته

الگوریتم های ADMM و نسخه پیشرفته آن (ADMM-Enhanced) در سه سناریو مختلف توپولوژی پیشرفته ارزیابی شدند. در سناریوی شبکه پایدار (جدول ۹)، الگوریتم های پیشنهادی عملکرد بهتری نسبت به روش های کلاسیک مانند LFU-DA و LRU داشتند. این الگوریتم ها توانستند نرخ اصابت کَش بالاتری را ثبت کنند و در عین حال، درصد آلودگی کَش را به طور قابل توجهی کاهش دهند. همچنین، در این سناریو، نرخ اصابت برای محتوای پرتعدادار Top 100 و Top 50 در الگوریتم های ADMM و نسخه پیشرفته آن بالاترین میزان را داشت. در سناریوی حمله آلودگی کَش (CPA) (جدول ۱۰)، الگوریتم های ADMM و

ADMM-Enhanced به‌طور مؤثری آلودگی کَش را کاهش دادند و توانستند تعادل مناسبی بین نرخ اصابت و مقاومت در برابر آلودگی ایجاد کنند. در حالی که روش‌های کلاسیک نظیر LRU-DA و LFU-DA با کاهش قابل توجه در نرخ اصابت و افزایش آلودگی کَش مواجه شدند. در سناریوی تغییرات بار ترافیکی (پویا) (جدول ۱۱)، الگوریتم‌های ADMM و ADMM-Enhanced عملکرد پایدار و تطبیق‌پذیری خوبی در شرایط متغیر و پویا از خود نشان دادند. این الگوریتم‌ها توانستند نرخ اصابت کَش را در سطح مطلوب حفظ کرده و آلودگی کَش را کنترل کنند. در مقابل، روش‌های مرجع در شرایط تغییرات بار ترافیکی ضعیف عمل کردند. به‌طور کلی، نتایج این سناریوها نشان می‌دهند که الگوریتم‌های ADMM و ADMM-Enhanced در تمامی شرایط از نظر نرخ اصابت کَش، مقاومت در برابر آلودگی و مدیریت محتواهای پربازدید عملکرد بهتری نسبت به روش‌های مرجع دارند و به‌عنوان گزینه‌ای ایده‌آل برای شبکه‌های NDN پیشنهاد می‌شوند.

جدول ۹: سناریو توپولوژی پیشرفته ۱: شبکه پایدار (بدون حمله)

Table 9: advanced topology scenario 1: stable network (no attack)

الگوریتم	Top 50 نرخ اصابت	Top 100 نرخ اصابت	CPR (درصد آلودگی کَش)	CHR (نرخ اصابت کَش)
PFP-DA	80.00%	70.00%	8.00%	25.00%
LFU-DA	70.00%	60.00%	18.00%	18.00%
LRU	62.00%	52.00%	22.00%	15.00%
ADMM	82.00%	72.00%	6.00%	27.00%
ADMM-Enhanced	85.00%	75.00%	5.00%	29.00%

جدول ۱۰: سناریو ۲ توپولوژی پیشرفته: شبکه تحت حمله آلودگی کَش (CPA)

Table 10: Advanced Topology Scenario 2: Network Under CPA Attack

الگوریتم	Top 50 نرخ اصابت	Top 100 نرخ اصابت	CPR (درصد آلودگی کَش)	CHR (نرخ اصابت کَش)
PFP-DA	77.00%	65.00%	12.00%	23.00%
LFU-DA	60.00%	50.00%	30.00%	16.00%
LRU	48.00%	40.00%	32.00%	11.00%
ADMM	80.00%	68.00%	10.00%	25.00%
ADMM-Enhanced	82.00%	70.00%	8.00%	27.00%

جدول ۱۱: سناریو ۳ توپولوژی پیشرفته: تغییرات بار ترافیکی (پویا)

Table 11: scenario 3 advanced topology: traffic load changes (dynamic)

الگوریتم	Top 50 نرخ اصابت	Top 100 نرخ اصابت	CPR (درصد آلودگی کَش)	CHR (نرخ اصابت کَش)
PFP-DA	74.00%	63.00%	10.00%	21.00%
LFU-DA	56.00%	47.00%	24.00%	14.00%
LRU	52.00%	42.00%	26.00%	12.00%
ADMM	78.00%	66.00%	8.00%	24.00%
ADMM-Enhanced	80.00%	68.00%	7.00%	26.00%

۴-۶- نتایج ارزیابی برای توپولوژی مش

در ارزیابی عملکرد الگوریتم‌های کَش در توپولوژی مش که در سه سناریو مهم بررسی شد، تفاوت‌های چشمگیری میان روش‌های کلاسیک و الگوریتم‌های مبتنی بر بهینه‌سازی توزیع‌شده مشاهده شد. در سناریوی شبکه پایدار (جدول ۱۲)، الگوریتم‌های کلاسیک با محدودیت‌هایی در حفظ تعادل بین نرخ پاسخ‌دهی محتوا و کیفیت کَش مواجه شدند، در حالی که الگوریتم‌های مبتنی بر ADMM با ساختار تطبیقی خود، توانستند کارایی بالاتری را از نظر ذخیره‌سازی محتوای پرتعداد و کاهش داده‌های کم‌ارزش نشان دهند. در سناریوی حمله آلودگی کَش (جدول ۱۳)، تفاوت عملکرد میان روش‌های بهینه‌سازی‌شده و کلاسیک بیشتر شد. روش‌های سنتی که از فیلترهای ساده یا فرکانس دسترسی استفاده می‌کردند، در برابر محتوای آلوده آسیب‌پذیرتر بودند، در حالی که الگوریتم‌های ADMM، به‌ویژه نسخه پیشرفته آن، توانستند با استفاده از کنترل تطبیقی و ارزیابی دقیق‌تر ارزش محتوا، اثر حملات را کاهش دهند و کیفیت داده‌های ذخیره‌شده را حفظ کنند. در سناریوی تغییرات بار ترافیکی (پویا) (جدول ۱۴)، الگوریتم‌های ADMM با انعطاف‌پذیری بالا در تنظیم ساختار کَش و تصمیم‌گیری توزیع‌شده، توانستند در شرایط متغیر بار، عملکرد مطلوبی از خود نشان دهند و کیفیت کَش را حفظ کنند، در حالی که روش‌های غیرهوشمند دچار افت کارایی شدند. این نتایج نشان می‌دهند که الگوریتم‌های پیشرفته مانند ADMM، به‌ویژه نسخه پیشرفته آن، در تمامی شرایط از جمله شبکه‌های پایدار، حملات آلودگی کَش و محیط‌های پویا، عملکرد برتری نسبت به الگوریتم‌های

کلاسیک دارند. استفاده از این الگوریتم ها در توپولوژی های پیچیده مانند مش، نه تنها مزایای فنی بلکه مزایای عملیاتی قابل توجهی برای شبکه های داده محور فراهم می آورد.

جدول ۱۲: سناریو ۱ توپولوژی مش: شبکه پایدار (بدون حمله)

Table 12: Mesh topology scenario 1: stable network (no attack)

الگوریتم	Top 50 نرخ اصابت	Top 100 نرخ اصابت	(CPR) درصد آلودگی کش	(CHR) نرخ اصابت کش
PFP-DA	77.00%	67.00%	11.00%	20.00%
LFU-DA	63.00%	53.00%	21.00%	13.00%
LRU	57.00%	47.00%	27.00%	10.00%
ADMM	79.00%	69.00%	9.00%	22.00%
ADMM-Enhanced	81.00%	71.00%	8.00%	24.00%

جدول ۱۳: سناریو ۲ توپولوژی مش: حمله آلودگی کش (CPA)

Table 13: Mesh Topology Scenario 2: CPA

الگوریتم	Top 50 نرخ اصابت	Top 100 نرخ اصابت	(CPR) درصد آلودگی کش	(CHR) نرخ اصابت کش
PFP-DA	73.00%	61.00%	16.00%	18.50%
LFU-DA	49.00%	40.00%	35.00%	11.50%
LRU	33.00%	27.00%	37.00%	7.50%
ADMM	75.00%	64.00%	13.00%	20.00%
ADMM-Enhanced	78.00%	67.00%	11.00%	22.00%

جدول ۱۴: سناریو ۳ توپولوژی مش: تغییر بار ترافیکی (پویا)

Table 14: scenario 3 mesh topology: traffic load change (dynamic)

الگوریتم	Top 50 نرخ اصابت	Top 100 نرخ اصابت	(CPR) درصد آلودگی کش	(CHR) نرخ اصابت کش
PFP-DA	68.00%	58.00%	15.00%	17.00%
LFU-DA	50.00%	44.00%	29.00%	10.00%
LRU	46.00%	39.00%	31.00%	8.00%
ADMM	73.00%	62.00%	12.00%	19.00%
ADMM-Enhanced	76.00%	65.00%	10.00%	21.00%

۴-۷- مقایسه با مقاله پایه

در مقاله [۱۲]، دو سناریو برای بررسی تأثیر پارامتر β در الگوریتم PFP- β -DA ارائه شده است. سناریوی اول شرایط بدون حمله را بررسی می کند، که نشان می دهد کاهش β (به ویژه در محدوده ۰.۵) باعث بهبود نرخ اصابت کش و کاهش آلودگی کش می شود. سناریوی دوم مربوط به شرایط حمله است که با افزایش تعداد مهاجمین، عملکرد PFP- β -DA کاهش می یابد، به ویژه زمانی که تعداد مهاجمین بیشتر از ۱۵٪ شود. در این تحقیق، الگوریتم پیشنهادی مبتنی بر ADMM با تنظیم خودکار پارامترهای ρ و λ پیش بینی می شود که عملکرد بهتری نسبت به PFP- β -DA در شرایط پایدار و در مواجهه با حملات داشته باشد. این مقایسه به ارزیابی جامع تر روش پیشنهادی کمک می کند.

در جدول (۱۵) نتایج نشان می دهد که در شرایط پایدار بدون حمله، الگوریتم های ADMM و ADMM-Enhanced عملکرد بهتری نسبت به PFP-DA و PFP- β -DA دارند. PFP- β -DA با β بهینه (۰.۵) توانسته آلودگی کش را به صفر برساند، اما ADMM با بهینه سازی تطبیقی عملکرد بهتری در نرخ اصابت و کاهش آلودگی ثبت کرده است. نسخه پیشرفته ADMM (ADMM-Enhanced) نیز با تنظیم بهینه پارامترهای ρ و λ عملکرد بهتری در نرخ اصابت Top 100 و Top 50 داشت.

در سناریو دوم، جدول (۱۶)، که حمله با بار مهاجم ۵٪ بررسی شد، ADMM و ADMM-Enhanced به دلیل استفاده از تنظیم تطبیقی β توانستند نرخ اصابت کش و نرخ اصابت برای محتوای پرتعداد را نسبت به PFP- β -DA بهبود دهند و در برابر حملات مقاوم تر عمل کنند.

در سناریو سوم، جدول (۱۷)، که حمله با بار مهاجم ۳۰٪ بود، PFP- β -DA در برابر حملات سنگین عملکرد ضعیف تری نشان داد، زیرا β ایستا تغییرات لحظه ای را تطبیق نمی دهد. در مقابل، ADMM و ADMM-Enhanced با ساختار تطبیقی خود توانستند عملکرد بهتری در کاهش آلودگی و افزایش نرخ اصابت کش داشته باشند. ADMM-Enhanced به ویژه توانست درصد آلودگی را به ۱۸٪ و نرخ اصابت Top 50 را به ۷۳٪ برساند، که نشان دهنده انعطاف پذیری بالای آن در شرایط حملات شدید است. این تحلیل ها نشان می دهند که الگوریتم های ADMM و ADMM-Enhanced در شرایط مختلف عملکرد بهتری نسبت

به PFP- β -DA دارند، به‌ویژه با استفاده از β تطبیقی که در مواجهه با حملات سنگین و شرایط متغیر شبکه به‌طور مؤثرتر عمل می‌کند.

جدول ۱۵: مقایسه عملکرد الگوریتم‌ها در سناریو ۱ (بدون حمله)

Table 15: comparing the performance of algorithms in scenario 1 (no attack)

الگوریتم	Top 50 نرخ اصابت	Top 100 نرخ اصابت	(CPR) درصد آلودگی کش	(CHR) نرخ اصابت کش
PFP-DA	75.5%	68.2%	10.3%	21.3%
PFP- β -DA ($\beta=0.05$)	98.8%	93.1%	0.0%	25.0%
ADMM	99.0%	95.0%	0.0%	28.0%
ADMM-Enhanced	99.5%	96.5%	0.0%	30.0%

جدول ۱۶: مقایسه عملکرد الگوریتم‌ها در سناریو ۲ (حمله با تعداد مهاجمین متنوع) با ۵٪ بار مهاجم

Table 16: comparing the performance of algorithms in scenario 2 (attack with a diverse number of attackers) with 5% attacker load

الگوریتم	Top 50 نرخ اصابت	Top 100 نرخ اصابت	(CPR) درصد آلودگی کش	(CHR) نرخ اصابت کش
PFP-DA	75.0%	65.0%	10.0%	19.0%
PFP- β -DA ($\beta=0.05$)	80.0%	70.0%	0.0%	23.0%
ADMM	84.0%	74.0%	0.0%	26.0%
ADMM-Enhanced	87.0%	77.0%	0.0%	28.0%

جدول ۱۷: مقایسه عملکرد الگوریتم‌ها در سناریو ۲ (حمله با تعداد مهاجمین متنوع) با ۳۰٪ بار مهاجم

Table 17: comparing the performance of algorithms in scenario 2 (attack with a diverse number of attackers) with 30% attacker load

الگوریتم	Top 50 نرخ اصابت	Top 100 نرخ اصابت	(CPR) درصد آلودگی کش	(CHR) نرخ اصابت کش
PFP-DA	60.0%	50.0%	30.0%	10.0%
PFP- β -DA ($\beta=0.05$)	65.0%	55.0%	25.0%	12.0%
ADMM	70.0%	60.0%	20.0%	16.0%
ADMM-Enhanced	73.0%	63.0%	18.0%	18.0%

۴-۸- مقایسه کیفی توپولوژی‌ها

در یک ارزیابی جامع در جدول ۱۸ از عملکرد الگوریتم‌ها در چهار توپولوژی مختلف و سناریوهای گوناگون، مشخص شد که روش‌های کلاسیک مانند LRU و LFU-DA در شرایط پویای شبکه و توپولوژی‌های پیچیده مانند مش عملکرد ضعیفی دارند. الگوریتم‌های آماری نظیر PFP-DA و PFP- β -DA در شرایط پایدار کارایی بهتری از خود نشان دادند، اما با افزایش بار حمله یا تغییرات شدید شبکه، دچار افت عملکرد شدند. در مقابل، الگوریتم‌های پیشنهادی ADMM و ADMM-Enhanced در تمام توپولوژی‌ها و سناریوها، از جمله حملات شدید، ازدحام یا تغییرات بار، عملکردی پایدار، تطبیق‌پذیر و مقاوم از خود نشان دادند. به‌ویژه ADMM-Enhanced با تنظیم دقیق پارامترهای تطبیقی، توانست کیفیت کش و نرخ اصابت را حتی در شرایط استرس‌زای شبکه حفظ کند.

جدول ۱۸: مقایسه کیفی الگوریتم‌ها در تمامی توپولوژی‌ها و سناریوهای تعریف‌شده

Table 18: qualitative comparison of algorithms in all defined topologies and scenarios

توپولوژی / سناریو	الگوریتم	نرخ اصابت کش (CHR)	مقاومت در برابر آلودگی (CPR)	حفظ محتوای محبوب	پایداری در بار متغیر	تطبیق‌پذیری ساختاری
ساده	LRU	ضعیف	ضعیف	متوسط	ضعیف	ضعیف
	LFU-DA	متوسط	ضعیف	متوسط	ضعیف	ضعیف
	PFP-DA	خوب	متوسط	خوب	متوسط	متوسط
	ADMM	خوب	خوب	خوب	خوب	خوب
	ADMM-Enhanced	عالی	عالی	عالی	عالی	بالا
سلسله‌مراتبی	LRU	ضعیف	بسیار ضعیف	ضعیف	ضعیف	ضعیف
	LFU-DA	ضعیف	ضعیف	ضعیف	ضعیف	ضعیف
	PFP-DA	متوسط	متوسط	متوسط	متوسط	متوسط
	ADMM	خوب	خوب	خوب	خوب	خوب

پیشرفته	ADMM-Enhanced LRU	عالی	عالی	عالی	عالی	بالا
	LFU-DA	ضعیف	ضعیف	ضعیف	ضعیف	ضعیف
	PFP-DA	متوسط	متوسط	متوسط	متوسط	متوسط
	ADMM	خوب	خوب	خوب	خوب	خوب
مش fault – tolerance	ADMM-Enhanced LRU	عالی	عالی	عالی	عالی	بالا
	LFU-DA	ضعیف	ضعیف	ضعیف	ضعیف	بسیار ضعیف
	PFP-DA	متوسط	متوسط	خوب	متوسط	ضعیف
	ADMM	خوب	خوب	خوب	خوب	متوسط
مقاله پایه – بدون حمله ($\beta=0.05$)	ADMM-Enhanced PFP- β -DA	عالی	عالی	عالی	عالی	خوب
	ADMM	عالی	عالی	عالی	عالی	بالا
	ADMM-Enhanced PFP- β -DA	عالی+	عالی+	عالی+	عالی+	بسیار بالا
	ADMM	متوسط	متوسط	متوسط	ضعیف	متوسط
مقاله پایه – حمله ۳۰٪ مهاجم	ADMM	خوب	خوب	خوب	خوب	خوب
	ADMM-Enhanced	عالی	عالی	عالی	عالی	بالا

۵- نتیجه گیری

در این پژوهش، باهدف مقابله هوشمندانه و تطبیق پذیر با چالش های مدیریت کش در معماری شبکه های داده های نام گذاری شده (NDN)، الگوریتمی مبتنی بر ADMM و نسخه بهبود یافته آن (ADMM-Enhanced) طراحی و ارزیابی شد. این الگوریتم با تنظیم پویا و توزیع شده پارامتر کلیدی β ، و همچنین بهینه سازی هم زمان ρ و λ ، توانست در سناریوهای متنوع شامل شبکه پایدار، حملات آلودگی کش و تغییرات شدید بار، عملکردی برتر نسبت به روش های مرجع مانند LRU، LFU-DA و حتی PFP- β -DA از خود نشان دهد. نتایج شبیه سازی در توپولوژی های مختلف از ساده تا مش نشان داد که ADMM-Enhanced در حفظ نرخ بالای اصابت کش و کاهش چشمگیر آلودگی، به ویژه در شرایط ناپایدار و مهاجم پذیر، بسیار موفق بوده و از نظر عددی و عملی به عنوان یک راهکار مقیاس پذیر و مقاوم برای مدیریت هوشمند کش در نسل آینده شبکه های داده محور قابل اتکا است.

مراجع:

- [1] F. A. Karim, A. H. M. Aman, R. Hassan, K. Nisar, and M. Uddin, "Named Data Networking: A Survey on Routing Strategies," IEEE Access, vol. 10, pp. 90254-90270, 2022.
- [2] X. Zhang, Y. Zhou, D. Wu, Q. Z. Sheng, S. Riaz, M. Hu, and L. Xiao, "A Survey on Privacy-Preserving Caching at Network Edge: Classification, Solutions, and Challenges," ACM Computing Surveys, vol. 57, no. 5, pp. 1-38, 2025.
- [3] P. Kar, L. Chen, W. Sheng, C. F. Kwong, and D. Chieng, "Advancing NDN security: Efficient identification of cache pollution attacks through rank comparison," Internet of Things, vol. 26, pp. 101142, 2024.
- [4] R. Alubady, M. Salman, and A. S. Mohamed, "A review of modern caching strategies in named data network: Overview, classification, and research directions," Telecommunication Systems, vol. 84, no. 4, pp. 581-626, 2023.
- [5] N. Sadat, and R. Dai, "A Survey of Quality-of-Service and Quality-of-Experience Provisioning in Information-Centric Networks," Network, vol. 5, no. 2, pp. 10, 2025.
- [6] A. H. Magsi, A. Ghulam, S. Memon, K. Javeed, M. Alhussein, and I. Rida, "A machine learning-based attack detection and prevention system in vehicular named data networking," Comput. Mater. Contin., vol. 77, no. 2, pp. 1445-1465, 2023.
- [7] A. Karami, and M. Guerrero-Zapata, "An anfis-based cache replacement method for mitigating cache pollution attacks in named data networking," Computer Networks, vol. 80, pp. 51-65, 2015.

- [8] N. U. Saqib, and S. Isnain, "A Survey on Mitigation of Cache Pollution Attacks in NDN," *Acta Technica Jaurinensis*, 2025.
- [9] Z. N. S. ALMUDAYNI, "Improving Energy Efficiency and Network Lifetime in IoT Systems: A Novel Theoretical Framework and Experimental Validation," *La Trobe*, 2025.
- [10] N. Kumar, and S. Srivastava, "IBPC: An Approach for Mitigation of Cache Pollution Attack in NDN using Interface-Based Popularity," *Arabian Journal for Science and Engineering*, vol. 49, no. 3, pp. 3241-3251, 2024.
- [11] T. Lauinger, N. Laoutaris, P. Rodriguez, T. Strufe, E. Biersack, and E. Kirda, "Privacy risks in named data networking: What is the cost of performance?," *ACM SIGCOMM Computer Communication Review*, vol. 42, no. 5, pp. 54-57, 2012.
- [12] J. Baugh, and J. Guo, "Enhancing Cache Robustness in Information-Centric Networks: Per-Face Popularity Approaches," *Network*, vol. 3, no. 4, pp. 502-521, 2023.
- [13] S. S. Ullah, S. Hussain, I. Ali, H. Khattak, and S. Mastorakis, "Mitigating content poisoning attacks in named data networking: a survey of recent solutions, limitations, challenges and future research directions," *Artificial Intelligence Review*, vol. 58, no. 2, pp. 42, 2024.
- [14] U. Sadana, A. Chenreddy, E. Delage, A. Forel, E. Frejinger, and T. Vidal, "A survey of contextual optimization methods for decision-making under uncertainty," *European Journal of Operational Research*, vol. 320, no. 2, pp. 271-289, 2025.
- [15] R. Tourani, S. Misra, T. Mick, and G. Panwar, "Security, privacy, and access control in information-centric networking: A survey," *IEEE communications surveys & tutorials*, vol. 20, no. 1, pp. 566-600, 2017.
- [16] Y. Xiao, H. Cui, R. A. Khurma, and P. A. Castillo, "Artificial lemming algorithm: a novel bionic meta-heuristic technique for solving real-world engineering optimization problems," *Artificial Intelligence Review*, vol. 58, no. 3, pp. 84, 2025.
- [17] T. Semwal, S. Jain, A. Mohanta, and A. Jain, "A hybrid CNN-SVM model optimized with PSO for accurate and non-invasive brain tumor classification," *Neural Computing and Applications*, pp. 1-30, 2025.
- [18] D. Han, and X. Yuan, "A note on the alternating direction method of multipliers," *Journal of Optimization Theory and Applications*, vol. 155, pp. 227-238, 2012.
- [19] S. G. Mandapati, C. Ranaweera, and R. Doss, "Early Detection and Mitigation of Cache-Based Attacks in IoT-NDN," *Deakin University*, 2025.
- [20] J. Yang, K. Ding, K. Xue, J. Han, D. S. L. Wei, Q. Sun, and J. Lu, "HPR-DS: A Hybrid Proactive Reactive Defense Scheme Against Interest Flooding Attack in Named Data Networking," *IEEE Transactions on Networking*, pp. 1-16, 2025.
- [21] H. Wang, D. Man, S. Han, H. Wang, and W. Yang, "Detection and Defense of Cache Pollution Attack Using State Transfer Matrix in Named Data Networks." pp. 545-556.
- [22] M. M. F. Hamdi, Z. Chen, and M. Radenkovic, "Mitigating Cache Pollution Attack Using Deep Learning in Named Data Networking (NDN)." pp. 432-442.
- [23] A. Hidouri, H. Touati, M. Hadded, N. Hajlaoui, P. Muhlethaler, and S. Bouzefrane, "Q-ICAN: A Q-learning based cache pollution attack mitigation approach for named data networking," *Computer Networks*, vol. 235, pp. 109998, 2023/11/01/, 2023.
- [24] L. Liu, and S. Peng, "Detection of A Novel Dual Attack in Named Data Networking." pp. 1-8.
- [25] D. Man, Y. Mu, J. Guo, W. Yang, J. Lv, and W. Wang, "Cache pollution detection method based on GBDT in information-centric network," *Security and Communication Networks*, vol. 2021, no. 1, pp. 6658066, 2021.
- [26] L. Yao, Y. Zeng, X. Wang, A. Chen, and G. Wu, "Detection and defense of cache pollution based on popularity prediction in named data networking," *IEEE Transactions on Dependable and Secure Computing*, vol. 18, no. 6, pp. 2848-2860, 2020.
- [27] J. Zhou, J. Luo, L. Deng, and J. Wang, "Cache pollution prevention mechanism based on cache partition in V-NDN." pp. 330-335.
- [28] R. M. Buvanessvari, and K. Suresh Joseph, "RBFNN: A radial basis function neural network model for detecting and mitigating the cache pollution attacks in named data networking," *IET Networks*, vol. 9, no. 5, pp. 255-261, 2020.
- [29] T. Nguyen, H. L. Mai, R. Cогranne, G. Doyen, W. Mallouli, L. Nguyen, M. E. Aoun, E. M. D. Oca, and O. Festor, "Reliable Detection of Interest Flooding Attack in Real Deployment of Named Data Networking," *IEEE Transactions on Information Forensics and Security*, vol. 14, no. 9, pp. 2470-2485, 2019.
- [30] B. K. Saha, and S. Misra, "Mitigating NDN-based fake content dissemination in opportunistic mobile networks," *IEEE Transactions on Mobile Computing*, vol. 19, no. 6, pp. 1375-1386, 2019.
- [31] J. P. Baugh, "Enhancing Cache Robustness in Named Data Networks," 2018.

- [32] A. Hidouri, H. Touati, M. Hadded, N. Hajlaoui, and P. Muhlethaler, "A detection mechanism for cache pollution attack in named data network architecture." pp. 435-446.