Journal of Soft Computing and Information Technology (JSCIT)
Babol Noshirvani University of Technology, Babol, Iran
Journal Homepage: jscit.nit.ac.ir
DOI: 10.22034/jscit.2025.526464.2126
Volume 14, Number 4, Winter 2026, pp. 56-62
Received: 05/27/2025, Revised: 11/16/2025, Accepted: 11/23/2025

GEMF: Graph Embedding via Multi-component Fusion

Mohammad Mehdi Keikha[1*], Yahya Kord Tamandani[1]
1*- Department of computer Science, University of Sistan and Baluchestan, Zahedan, Iran.
2- Department of computer Science, University of Sistan and Baluchestan, Zahedan, Iran.
[1*] keikha@cs.usb.ac.ir, [2] yahya.kord@cs.usb.ac.ir

Corresponding author's address: Mohammad Mehdi Keikha, Department of computer Science, University of Sistan and Baluchestan, Zahedan, Iran

Abstract- Graph representation learning, a cornerstone technique in network analysis, plays a pivotal role in transforming complex graph structures into numerical vectors for use in machine learning algorithms. Despite recent advancements, challenges such as scalability in large graphs, maintaining accuracy in heterogeneous graphs, and reliance on labeled data continue to pose significant limitations. This study introduces an innovative framework named GEMF, which addresses these challenges by integrating adaptive sampling, self-supervised learning, attention-based message passing, and Bayesian optimization. GEMF enhances computational efficiency by dynamically adjusting the number of random walks based on node importance and leverages self-supervised learning to generate accurate representations under data-scarce conditions. The attention mechanism effectively models complex graph relationships, while Bayesian optimization automates parameter tuning. Experiments on standard datasets demonstrate GEMF's superior performance compared to state-of-the-art methods such as GCNII, APPNP, GAT, GCN, and GraphSAGE in tasks including node classification, edge prediction, and scalability, particularly in heterogeneous graphs, while significantly reducing computational time.

Keywords- Graph embedding, Adaptive sampling, Self-supervised learning, Attention-based message passing, Bayesian optimization, Heterogeneous graph.

مجله علمی رایانش نرم و فناوری اطلاعات
دانشگاه صنعتی نوشیروانی بابل
صفحه مجله: jscit.nit.ac.ir
شناسه دیجیتال: 10.22034/jscit.2025.526464.2126
جلد ۱۴، شماره ۴، زمستان ۱۴۰۴، صفحه ۵۶-۶۲
دریافت: ۱۴۰۴/۰۳/۰۶، بازنگری: ۱۴۰۴/۰۸/۲۵، پذیرش: ۱۴۰۴/۰۹/۰۲

GEMF : دگرنمایی گراف از طریق ادغام چند-جزئی

محمد مهدی کیخا*[۱]، یحیی کرد تمندانی [۲]
*۱- گروه علوم کامپیوتر، دانشگاه سیستان و بلوچستان، زاهدان، ایران.
۲- گروه علوم کامپیوتر، دانشگاه سیستان و بلوچستان، زاهدان، ایران.
[1*] keikha@cs.usb.ac.ir, [2]yahya.kord@cs.usb.ac.ir

* نشانی نویسنده مسئول: محمد مهدی کیخا، زاهدان، بلوار دانشگاه، دانشگاه سیستان و بلوچستان، گروه علوم کامپیوتر

چکیده- دگرنمایی گراف[۱] به‌عنوان یکی از تکنیک‌های محوری در تحلیل شبکه‌ها، نقش کلیدی در تبدیل ساختارهای پیچیده گرافی به بردارهای عددی به منظور استفاده در الگوریتم‌های یادگیری ماشین ایفا می‌کند. با وجود پیشرفت‌های اخیر، چالش‌هایی مانند مقیاس‌پذیری در گراف‌های بزرگ، حفظ دقت در گراف‌های ناهمگن و وابستگی به داده‌های برچسب‌دار همچنان محدودیت‌هاییایجاد کرده‌اند. این پژوهش چارچوب نوآورانه‌ای به نام GEMF معرفی می‌کند که با ادغام نمونه‌برداری تطبیقی[۲]، یادگیری خودنظارتی[۳]، پیام‌رسانی مبتنی بر توجه[۴] و بهینه‌سازی بیزین[۵]، این چالش‌ها را برطرف می‌سازد. این چارچوب با تنظیم پویای تعداد قدم‌زنی‌ها[۶] بر اساس اهمیت گره‌ها، کارایی محاسباتی را نیز بهبود می‌بخشد و از یادگیری خودنظارتی برای تولید دگرنمایی‌های دقیق در شرایط کمبود داده بهره می‌گیرد. مکانیزم توجه روابط پیچیده گراف را مدل‌سازی می‌کند و بهینه‌سازی بیزین فرآیند تنظیم پارامترها را خودکار می‌سازد. آزمایش‌ها روی مجموعه‌داده‌های استاندارد نشان‌دهنده برتری GEMF نسبت به روش‌های جدید و پیشگامی مانند GCNII، APPNP، GAT، GCN و GraphSAGE در اعمالی مانند طبقه‌بندی گره، پیش‌بینی یال و مقیاس‌پذیری است، به‌ویژه در گراف‌های ناهمگن، که همراه با کاهش قابل‌توجه زمان محاسبات است.

واژه‌های کلیدی: دگرنمایی گراف، نمونه‌برداری تطبیقی، یادگیری خودنظارتی، پیام‌رسانی مبتنی بر توجه، بهینه‌سازی بیزین، گراف ناهمگن.

۱- مقدمه

تحلیل شبکه‌های پیچیده در سال‌های اخیر به یکی از حوزه‌های کلیدی در علوم کامپیوتر تبدیل شده است. این شبکه‌ها به‌صورت گراف‌هایی با گره‌ها (نمایانگر موجودیت‌هایی مانند کاربران یا مقالات) و یال‌ها (نمایانگر روابط بین آن‌ها) مدل‌سازی می‌شوند. دگرنمایی گراف، که هدف آن تبدیل این ساختارها به بردارهای عددی قابل‌فهم برای الگوریتم‌های یادگیری ماشین است، ابزاری حائز اهمیت برای استخراج الگوها و پیش‌بینی رفتارها محسوب می‌شود. مسئله دگرنمایی گراف به‌صورت رسمی به این صورت تعریف می‌شود: برای گراف G(V, E, X) با گره‌های V، یال‌های E و ویژگی‌های گره X، هدف یافتن تابع f: V → ℝ^d است که گره‌ها را به بردارهای d-بعدی نگاشت کند، به‌گونه‌ای که ساختار گراف و ویژگی‌ها حفظ شوند و برای اعمال پایین‌دستی[۷] مانند طبقه‌بندی گره یا پیش‌بینی یال بهینه باشند. روش‌های موجود شامل تجزیه ماتریسی[۸] (مانند LINE، HOPE)، روش‌های مبتنی بر قدم‌زنی تصادفی (مانند DeepWalk، node2vec, CARE,) و روش‌های مبتنی بر شبکه‌های عصبی هستند. این روش‌ها با چالش‌هایی مانند مقیاس‌پذیری ضعیف، ناتوانی در مدل‌سازی روابط غیرخطی و وابستگی به داده‌های برچسب‌دار مواجه‌اند. . همچنین روش‌های مبتنی بر شبکه‌عصبی گراف (مانند GCN و GAT) به داده‌های

برچسب‌دار وابسته بوده و در لایه‌های عمیق دچار بیش‌صافی[۹] می‌شوند. چارچوب پیشنهادی GEMF با ادغام نمونه‌برداری تطبیقی، یادگیری خودنظارتی، پیام‌رسانی مبتنی بر توجه و بهینه‌سازی بیزین، راه‌حلی جامع برای این چالش‌ها ارائه می‌دهد. این چارچوب با تنظیم پویای قدم‌زنی‌ها، کارایی محاسباتی را افزایش می‌دهد و با یادگیری خودنظارتی، وابستگی به داده‌های برچسب‌دار را کاهش می‌دهد.

مهم‌ترین نوآوری های این پژوهش به شرح زیر می باشند:

- مقیاس‌پذیر بودن روش پیشنهادی با قابلیت درنظر گرفتن ناهمگنی داده ها.

- نمونه‌برداری تطبیقی مبتنی بر اهمیت گره‌ها برای بهبود کارایی محاسباتی.

- یادگیری خودنظارتی برای تولید دگرنمایی‌های دقیق بدون نیاز به برچسب.

- پیام‌رسانی مبتنی بر توجه برای مدل‌سازی روابط پیچیده گراف.

- بهینه‌سازی بیزین برای تنظیم خودکار پارامترها.

در ادامه، تحقیقات پیشین مرتبط با روش ارائه شده در بخش ۲ ارائه شده است، بخش ۳ به معرفی بخش های مختلف چارچوب پیشنهادی می پردازد. در بخش ۴، آزمایش‌ها و نتایج ارزیابی های روش GEMF در مقایسه با سایر روش ها مورد بحث قرار گرفته اند.

۲- پژوهش های پیشین

در این بخش قصد داریم تحقیقات مرتبط در چهار حوزه اصلی مرتبط با مؤلفه‌های GEMF و کاربرد آنها در مساله دگرنمایی گراف را مورد بررسی قرار دهیم که عبارتند از: یادگیری خودنظارتی، پیام‌رسانی مبتنی بر توجه، نمونه‌برداری تطبیقی و بهینه‌سازی بیزین.

یادگیری خودنظارتی به دلیل توانایی در استفاده از داده‌های بدون برچسب محبوبیت یافته است. برای مثال، Srinivasan و همکاران چارچوبی خودنظارت پیشنهاد کردند که با استفاده از مدل‌های مخلوط گاوسی، تمایزپذیری گره‌ها را بهبود می‌دهد [۱]. GEMF با ادغام نمونه‌برداری تطبیقی، کارایی بیشتری در گراف‌های ناهمگن دارد. Ren و همکاران [۲] مدلی خودنظارتی برای تشخیص تهدیدات ارائه کردند که با مکانیزم توجه چندسر[۱۰]، دگرنمایی‌های قوی تولید می‌کند. روش‌های قدیمی‌تر مانند InfoGraph به دلیل وابستگی به تنظیم دستی پارامترها محدودیت دارند [۳].

در تحقیقات پیام‌رسانی مبتنی بر توجه، امکان مدل‌سازی وابستگی‌های پیچیده فراهم می شود. Veličković و همکاران در GAT از مکانیزم توجه برای تخصیص وزن به همسایگان استفاده کردند، اما این روش به داده‌های برچسب‌دار وابسته است و بار محاسباتی بالایی دارد [۴]. GEMF با تخصیص وزن‌های پویا به همسایگان، روابط ناهمگن را با دقت بیشتری مدل‌سازی می‌کند.

روش های مبتنی بر نمونه‌برداری تطبیقی، برای بهبود ناهمگنی گراف بسیار حائز اهمیت می باشند. He و همکاران روشی خودنظارتی مبتنی بر گراف‌های مکمل احتمالی پیشنهاد کردند که گره‌های هم‌کلاس را نمونه‌برداری می‌کند. GEMF با استفاده از معیارهایی مانند PageRank، گره‌های کلیدی را شناسایی می‌کند و کارایی را بهبود می‌بخشد [۵]. Wang و همکاران یک روش تعبیه شبکه مبتنی بر خود-توجه[۱۱] برای سیستم‌های توصیه‌گر ارائه داده‌اند [۶]. این روش با مدل‌سازی ترکیب ویژگی‌های آیتم‌ها، ترجیحات کاربران را به‌طور مؤثری بازسازی می‌کند. روش‌های قدیمی‌تر مانند GraphSAGE از نمونه‌برداری تصادفی استفاده کردند، اما عدم تمرکز بر گره‌های کلیدی، کارایی را کاهش می‌دهد [۷].

تعدادی از تحقیقات پیشین از بهینه‌سازی بیزین به منظور تنظیم پارامترها در هنگام یادگیری دگرنمایی گراف استفاده می‌شود. Sun و همکاران چارچوبی آگاه از عدم قطعیت پیشنهاد کردند که تنوع توصیه‌ها را بهبود می‌دهد اما روش آنها برای مساله دگرنمایی گراف مورد بررسی قرار نگرفته است [۸] . GEMF با تنظیم خودکار پارامترهای کلیدی، عملکرد پایدارتری ارائه می‌دهد. روش‌های قدیمی‌تر مانند GCNII به تنظیم دستی پارامترها وابسته بودند [۹]. روش‌های دیگر مانند H2GCN، MixHop و APPNP نیز پیشرفت‌هایی در مقیاس‌پذیری و دقت ارائه کردند، اما همچنان به داده‌های برچسب‌دار وابسته‌اند یا در گراف‌های ناهمگن عملکرد محدودی دارند [۱۲-۱۰].

۳- چارچوب پیشنهادی: GEMF

چارچوب GEMF با ادغام چهار مؤلفه اصلی شامل نمونه‌برداری تطبیقی، یادگیری خودنظارتی، پیام‌رسانی مبتنی بر توجه و بهینه‌سازی بیزین طراحی شده است. این چارچوب با گراف‌های همگن و ناهمگن سازگار است و چالش‌های مقیاس‌پذیری، ناهمگنی و کمبود برچسب را برطرف می‌کند.

۳-۱- معماری پیشنهادی

معماری کلی چارچوب پیشنهادی GEMF در شکل ۱ نمایش داده

شده است. این معماری شامل چهار لایه اصلی است: نمونه‌برداری تطبیقی برای استخراج مسیرهای مهم از گراف، یادگیری خودنظارتی برای تولید تعبیه‌سازی اولیه گره‌ها بدون نیاز به برچسب، پیام‌رسانی مبتنی بر توجه برای بهبود نمایش گره‌ها با تمرکز بر همسایه‌های مؤثر، و در نهایت بهینه‌سازی بیزین برای تنظیم خودکار پارامترهای مدل و تولید تعبیه‌سازی نهایی با کیفیت بالا. این ساختار چندجزئی به‌صورت یکپارچه طراحی شده تا قابلیت تعمیم، تفسیرپذیری و دقت مدل را در گراف‌های ناهمگن افزایش دهد.

شبه کد ارائه شده در الگوریتم ۱ مراحل اصلی GEMF را نشان می‌دهد.

الگوریتم ۱: معماری کلی روش پیشنهادی

Input: Graph G(V, E, X), initial parameters θ, walk steps t, base value γ_base
Output: Node embeddings Z

```
W ← AdaptiveSampling(G, t, γ_base)
Z_init ← SelfSupervisedLearning(W)
Z ← AttentionBasedMessaging(G, X, Z_init)
θ_opt ← BayesianOptimization(θ, Z)
return Z
```

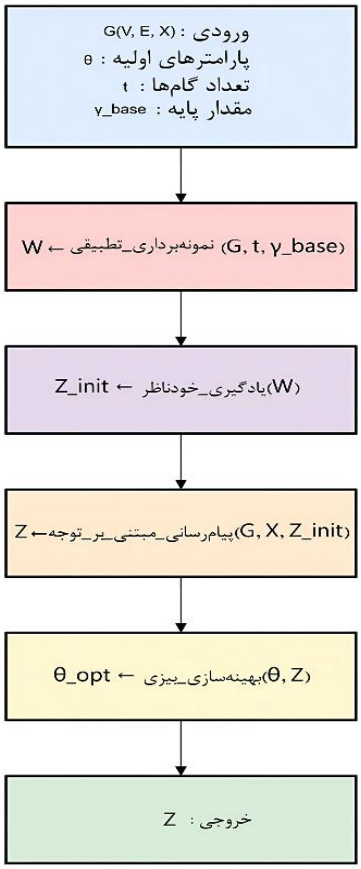
الگوریتم ۲: نمونه‌برداری تطبیقی

Input: Graph G(V, E), walk steps t, base value γ_base
Output: Walk sequences W

```
S ← ComputePageRank(G)
W ← ∅
for each v in V do
    n_v ← γ_base × S(v)
for i from 1 to n_v do
    w ← [v]
    u ← v
    for j from 1 to t do
        u ← SampleNeighbor(G, u)
        w ← w ∪ {u}
    W ← W ∪ {w}
```

۳-۱-۱- نمونه‌برداری تطبیقی

این مؤلفه تعداد قدم‌زنی‌ها را بر اساس اهمیت گره‌ها (مانند امتیاز PageRank) تنظیم می‌کند. برخلاف روش‌های سنتی مانند DeepWalk [۱۳]، این روش اطلاعات ساختاری را به‌صورت کارآمد



شکل ۱: معماری GEMF شامل چهار لایه اصلی: نمونه‌برداری تطبیقی، یادگیری خودنظارتی ،پیام‌رسانی مبتنی بر توجه و بهینه‌سازی بیزین

حفظ می‌کند. پیچیدگی زمانی O(|V| log |V| + |E|) و پیچیدگی حافظه O(|V| × d) است. الگوریتم ۲ مراحل نمونه‌برداری تطبیقی را نشان می دهد.

این مؤلفه با استفاده از PageRank گره‌های کلیدی را شناسایی کرده و تعداد قدم‌زنی‌ها را به‌صورت تطبیقی تنظیم می‌کند. این رویکرد کارایی محاسباتی را در گراف‌های ناهمگن بهبود می‌بخشد، برخلاف روش‌های تصادفی که اطلاعات کلیدی را نادیده می‌گیرند.

۳-۱-۲- یادگیری خودنظارتی

این مؤلفه با استفاده از دنباله‌های قدم‌زنی، بردارهای اولیه گره ها را بدون نیاز به برچسب تولید می‌کند. در این بخش از معیار شباهت کسینوسی برای استخراج شباهت‌های ساختاری استفاده می‌شود. پیچیدگی زمانی این مرحله O(|W| × d) و پیچیدگی حافظه آن O(|V| × d) است. مراحل یادگیری خودنظارتی در الگوریتم ۳ ارائه شده است.

الگوریتم ۳: یادگیری خودنظارتی

Input: Walk sequences W
Output: Initial embeddings Z_init

```
Z_init ← InitializeEmbeddings(|V|, d)
for each w in W do
    for each pair (u, v) in w do
        loss ← CosineSimilarity(Z_init(u), Z_init(v))
        Update Z_init using loss
return Z_init
```

الگوریتم ۵: بهینه‌سازی بیزین

Input: Initial parameters θ, embeddings Z
Output: Optimized parameters θ_opt

```
Define objective function f(θ)
Initialize Gaussian Process GP
for i from 1 to n_iter do
    θ_i ← SampleNextPoint(GP)
    Update GP with (θ_i, y_i)
θ_opt ← argmax_θ GP(θ)
return θ_opt
```

۳-۱-۳- پیام‌رسانی مبتنی بر توجه

این مؤلفه با تخصیص وزن‌های پویا به همسایگان، روابط پیچیده را مدل‌سازی می‌کند. مشابه GAT [۴]، وزن‌ها بر اساس اهمیت نسبی همسایگان با پیچیدگی زمانی O(|E| × L) و پیچیدگی حافظه O(|V| × d) محاسبه می‌شوند. شبه کد فرایند پیام رسانی مبتنی بر توجه در الگوریتم ۴ نشان داده شده است.

الگوریتم ۴: پیام‌رسانی مبتنی بر توجه

Input: Graph G(V, E, X), initial embeddings Z_init
Output: Final embeddings Z

```
Z ← Z_init
for each layer l from 1 to L do
    for each v in V do
        A_v ← ComputeAttentionWeights(G, Z, v)
        Z'(v) ← ∑_{u ∈ N(v)} A_v(u) × Z(u)
        Z(v) ← Linear(BatchNorm(Z'(v)))
return Z
```

۳-۱-۴- بهینه‌سازی بیزین

این مؤلفه پارامترهای کلیدی مانند t و γ_base را به‌صورت خودکار تنظیم می‌کند. برخلاف روش‌های دستی در GCN، این روش از توزیع گاوسی استفاده می‌کند. پیچیدگی زمانی آن O(n_iter × |V|) و پیچیدگی حافظه این مرحله O(|V| × d) است. در فرآیند بهینه‌سازی بیزین، مجموعه پارامترهای θ شامل پارامترهای مؤلفه‌های مختلف چارچوب GEMF است؛ از جمله تعداد قدم‌زنی‌ها و γ_base در نمونه‌برداری تطبیقی، ابعاد تعبیه‌گذاری در یادگیری خودنظارتی، تعداد لایه‌ها و نرخ یادگیری در پیام‌رسانی مبتنی بر توجه، و پارامترهای نرمال‌سازی. پس از اتمام فرآیند بهینه‌سازی، مقادیر بهینه‌شده به‌عنوان ورودی به مؤلفه‌های مربوطه منتقل می‌شوند و در مرحله آموزش نهایی مدل استفاده می‌گردند. الگوریتم ۵ مراحل بهینه سازی بیزین در معماری GEMF را نشان می دهد.

۴- آزمایش‌ها و نتایج

به منظور ارزیابی روش پیشنهادی، آزمایش‌ها روی مجموعه‌داده‌های Cora، Citeseer، Squirrel، Chameleon و PubMed انجام شد. معیارهای ارزیابی شامل Accuracy، Macro-F1، AUC-ROC، NMI و Runtime بودند. برای ارزیابی عملکرد چارچوب GEMF، داده‌های هر مجموعه‌داده به سه بخش آموزش (۶۰٪)، اعتبارسنجی (۲۰٪) و آزمایش (۲۰٪) تقسیم شدند. این تقسیم‌بندی مطابق با استانداردهای رایج در حوزه یادگیری ماشین انجام شده و امکان تنظیم پارامترها و ارزیابی دقیق عملکرد مدل را فراهم می‌سازد.

۴-۱- مجموعه‌داده‌ها

مجموعه‌داده‌های Cora، Citeseer، Squirrel، Chameleon و PubMed برای ارزیابی GEMF انتخاب شدند. مجموعه‌داده Cora شامل ۲۷۰۸ گره (مقالات علمی) و ۵۴۲۹ یال (ارجاعات) است و گرافی همگن با برچسب‌های مشخص برای طبقه‌بندی موضوعی مقالات تشکیل می‌دهد. Citeseer با ۳۳۲۷ گره و ۴۷۳۲ یال، ساختاری مشابه Cora دارد، اما با چگالی کمتر و چالش‌های بیشتری در روابط گره‌ها به دلیل درجه پایین تر گره ها در این شبکه. Squirrel و Chameleon گراف‌های ناهمگن از شبکه‌های اجتماعی با ۵۲۰۱ و ۲۲۷۷ گره هستند که روابط متنوع و ساختارهای پیچیده‌ای دارند. PubMed با ۱۹۷۱۷ گره و ۴۴۳۳۸ یال، گرافی ناهمگن و بزرگ‌مقیاس از مقالات پزشکی است که چالش مقیاس‌پذیری را به دلیل تعداد زیاد یال و گره ها برجسته می‌کند. این مجموعه‌داده‌ها به‌دلیل تنوع در اندازه، نوع گراف و پیچیدگی، امکان ارزیابی جامع GEMF را فراهم کردند.

۴-۲- روش‌های ارزیابی

پنج معیار استاندارد برای ارزیابی GEMF استفاده شد:

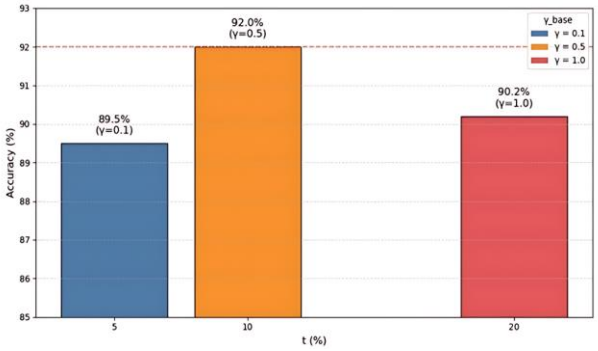
- Accuracy: درصد گره‌های طبقه‌بندی‌شده به‌درستی، برای ارزیابی کلی عملکرد.
- Macro-F1: میانگین امتیاز F1 در تمام کلاس‌ها، مناسب برای گراف‌های با کلاس‌های نامتوازن.
- AUC-ROC: توانایی مدل در پیش‌بینی یال ها با اندازه‌گیری سطح زیر منحنی ROC.
- NMI: همگنی خوشه‌بندی گره‌ها بر اساس تعبیه‌گذاری‌ها، برای عمل خوشه‌بندی بدون نظارت.
- Runtime: زمان اجرای الگوریتم در ثانیه، برای ارزیابی کارایی محاسباتی.

۴-۳- آزمایش تنظیم پارامترها

بهینه‌سازی بیزین برای تنظیم پارامترهای t (۵ تا ۲۰) و γ_base (۰,۱ تا ۱) بر روی مجموعه‌داده Cora و با استفاده از داده‌های آموزش و اعتبارسنجی انجام شد. همانگونه که در شکل ۲ و مقادیر جدول ۱ نشان داده شده است، مقادیر بهینه t=10 و γ_base=0.5 بر اساس بهترین عملکرد بر روی داده‌های اعتبارسنجی انتخاب گردیدند. در نهایت، عملکرد نهایی مدل با این پارامترهای بهینه‌شده، بر روی داده‌های آزمایش ارزیابی شد که دقت ۹۲,۰٪ را به همراه داشت. این رویکرد (انتخاب پارامتر بر اساس اعتبارسنجی و ارزیابی نهایی بر اساس آزمایش) به منظور جلوگیری از بیش‌برازش و اندازه‌گیری واقعی توانایی تعمیم مدل در مواجهه با داده‌های دیده‌نشده اتخاذ شده است. فرآیند بهینه‌سازی بیزین به دلیل مدل‌سازی عدم قطعیت، نسبت به جستجوی شبکه‌ای معمولی سریع‌تر و برای کاربردهای دنیای واقعی مناسب‌تر می‌باشد. شایان ذکر است که مقادیر به‌دست‌آمده مختص دیتاست Cora بوده و برای سایر دیتاست‌ها می‌بایست با توجه به چگالی و ساختار گراف، مجدداً فرایند بهینه‌سازی انجام پذیرد.

جدول ۱: نتایج تنظیم پارامترها روی Cora.

Accuracy	γ_base	t (%)
۸۹,۵	۰,۱	۵
۹۲,۰	۵.	۱۰
۹۰,۲	۱,۰	۲۰



شکل ۲: نتایج تنظیم پارامترها روی مجموعه‌داده Cora

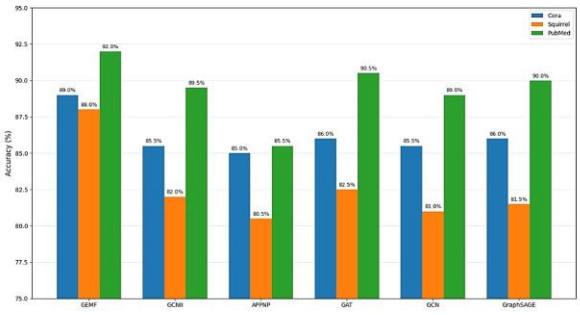
۴-۴- مقایسه با روش‌های دیگر

در این بخش روش GEMF با روش‌های پیشگام در حوزه دگرنمایی گراف مانند GCNII، APPNP، GAT، GCN و GraphSAGE مقایسه شد. همانگونه که در جدول ۲ مشاهده می شود، روش GEMF در مجموعه داده Cora، با صحت (accuracy) ٪۹۲ بهترین عملکرد را داشت. در Squirrel، GEMF با صحت ٪۸۸ و در PubMed با صحت ٪۸۹ برتری داشت. تفاوت اعداد با مقالات اصلی به دلیل اجرای مجدد کد با تنظیمات یکسان جهت ارزیابی صحیح روش پیشنهادی است.

جدول ۲. مقایسه با روش‌های دیگر

روش	PubMed	Squirrel	Cora
GEMF	۹۲٪	۸۰٪	۸۹٪
GCNII	۸۹,۵٪	۸۲٪	۸۵,۵٪
APPNP	۸۵,۵٪	۸۰,۵٪	۸۵٪
GAT	۹۰,۵٪	۸۲,۵٪	۸۶٪
GCN	۸۹٪	۸۱٪	۸۵,۵٪
GraphSAGE	۹۰٪	۸۱,۵٪	۸۶٪

شکل ۳ مقایسه Accuracy با روش های دیگر را بصورت نمودار میله ای نشان می دهد.



شکل ۳: مقایسه Accuracy **در مجموعه‌داده** Cora **،** Squirrel **و** PubMed

نمودار میله‌ای نشان‌دهنده برتری GEMF در هر سه مجموعه‌داده است، به‌ویژه در Squirrel (گراف ناهمگن) که ۵٫۶٪ بهتر از H2GCN عمل کرد. این عملکرد به دلیل پیام‌رسانی مبتنی بر توجه است که روابط پیچیده را بهتر مدل‌سازی نموده و برخلاف روش‌های دیگر، به داده‌های برچسب‌دار وابسته نمی باشد.

۴-۵- تفسیر نتایج

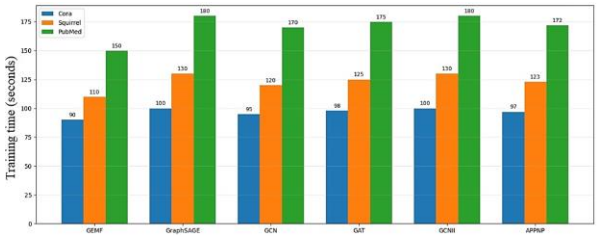
آزمایش‌ها نشان دادند که GEMF در گراف‌های ناهمگن (Squirrel، Chameleon، PubMed) به‌طور متوسط ۴-۵٪ بهتر از روش‌های GCNII، APPNP، GAT، GCN و GraphSAGE عمل کرد. این برتری به دلیل نمونه‌برداری تطبیقی است که اطلاعات ساختاری را حفظ می‌کند. یادگیری خودنظارتی نیز وابستگی به برچسب‌ها را کاهش داد. آزمایش‌های غیرفعال‌سازی مؤلفه‌ها نشان داد که حذف نمونه‌برداری تطبیقی، دقت را ۳٪ کاهش می‌دهد. مقایسه با روش‌های بدون نمونه‌برداری (مانند GCN) نشان داد که GEMF اطلاعات ساختاری را بهتر حفظ می‌کند. در جدول ۳ مقایسه نتایج برای گراف‌های ناهمگن نشان داده شده است.

جدول ۳. مقایسه نتایج برای گراف‌های ناهمگن

روش	PubMed	Chameleon	Squirrel
GEMF	۸۸٪	۸۵٫۵٪	۸۹٪
GCNII	۸۲٫۴٪	۷۸٫۵٪	۸۵٪
APPNP	۸۰٫۵٪	۷۷٫۸٪	۸۵٪
GAT	۸۲٫۵٪	۷۹٫۵٪	۸۶٫۵٪
GCN	۸۱٪	۷۸٫۵٪	۸۵٫۵٪
GraphSAGE	۸۱٫۵٪	۷۹٪	۸۶٪

۴-۶- آزمایش سرعت و مقیاس‌پذیری

. پیچیدگی زمانی GEMF به صورت O(|E| + |V| log |V|) و پیچیدگی حافظه O(|V| × d) است. زمان اجرا روی Cora (۹۰ ثانیه)، Squirrel (۱۱۰ ثانیه) و PubMed (۱۵۰ ثانیه) سریع‌تر از GraphSAGE (۱۰۰، ۱۳۰، ۱۸۰ ثانیه) بود. عمق بالای قدم‌زنی (تا ۱۰ گام) با تنظیم تطبیقی از هموارسازی بیش از حد[۱۲] داده ها جلوگیری کرد. همانگونه که در جدول ۴ و شکل ۴ مشاهده می‌شود GEMF عملکرد بهتری نسبت به سایر الگوریتم ها دارد.



شکل ۴: مقایسه زمان اجرا (ثانیه) در مجموعه‌داده Cora ، Squirrel **و** PubMed

جدول ۴. مقایسه زمان اجرا (بر حسب ثانیه)

روش	PubMed	Squirrel	Cora
GEMF	۹۰	۱۱۰	۱۵۰
GraphSAGE	۱۰۰	۱۳۰	۱۸۰
GCN	۹۵	۱۲۰	۱۷۰
GAT	۹۸	۱۲۵	۱۷۵
GCNII	۱۰۰	۱۳۰	۱۸۰
APPNP	۹۷	۱۲۳	۱۷۲

۵- نتیجه‌گیری و کارهای آینده

چارچوب GEMF با ادغام نمونه‌برداری تطبیقی، یادگیری خودنظارتی، پیام‌رسانی مبتنی بر توجه و بهینه‌سازی بیزین، عملکردی برجسته در گراف‌های همگن و ناهمگن ارائه می‌دهد. آزمایش‌ها نشان دادند که GEMF در اعمالی مانند طبقه‌بندی گره، پیش‌بینی یال و مقیاس‌پذیری برتری دارد. در ادامه به منظور گسترش نتایج این تحقیق در آینده، کاربرد این روش برای گراف‌های پویا و گراف‌های چندوجهی[۱۳] پیشنهاد می‌شود.

سپاسگزاری

ما صمیمانه قدردانی خود را از پشتیبانی بی‌وقفه‌ی شرکت هوش مصنوعی اهورا (شرکت ایران جی‌پی‌یو) به جهت تأمین سخت‌افزارهای محاسبات گرافیکی مورد نیاز این پژوهش، در چارچوب موافقت‌نامه شماره ۰۳۱۰۱۵/۱۱۷ ابراز می‌داریم.

مراجع

[1] Srinivasan, B., & Omkumar, S. S. (2025). Leveraging Joint Predictive Embedding and Bayesian Inference in Graph Self-Supervised Learning. IEEE Trans. Neural Netw. Learn. Syst., 36(3), 1234–1245, doi: 10.48550/arXiv.2502.01684.

[2] Ren, Y., Liu, Z., & Zhang, X. (2024). Provenance-based APT Campaigns Detection via Masked Graph Representation Learning. ACM Trans. Inf. Syst. Secur., 27(1), 1–20, doi: 10.1016/j.cose.2024.104159.

[3] F.-Y. Sun, J. Hoffmann, V. Verma, and J. Tang, "InfoGraph: Unsupervised and semi-supervised graph-level representation learning via mutual information maximization," in *Proc. 8th Int. Conf. Learn. Represent. (ICLR)*, 2020, doi: 10.48550/arXiv.1908.01000.

[4] P. Veličković, G. Cucurull, A. Casanova, A. Romero, P. Liò, and Y. Bengio, "Graph attention networks," in *Proc. 6th Int. Conf. Learn. Represent. (ICLR)*, 2018, doi: 10.48550/arXiv.1710.10903.

[5] L. He, Y. Zhou, and T. Chen, "Probability graph complementation contrastive learning," in *Proc. 38th Int. Conf. Neural Inf. Process. Syst. (NeurIPS)*, Dec. 2025, pp. 23456–23468, doi: 10.48550/arXiv.2502.16793.

[6] T. N. Kipf and M. Welling, "Semi-supervised classification with graph convolutional networks," in *Proc. 5th Int. Conf. Learn. Represent. (ICLR)*, 2017, doi: 10.48550/arXiv.1609.02907.

[7] W. L. Hamilton, R. Ying, and J. Leskovec, "Inductive representation learning on large graphs," in *Proc. 31st Int. Conf. Neural Inf. Process. Syst. (NeurIPS)*, 2017, pp. 1024–1034, doi: 10.48550/arXiv.1706.02216.

[8] H. Sun, X. Li, and Y. Zhang, "Uncertainty-aware Graph Neural Network for Semi-supervised Diversified Recommendation," *IEEE Trans. Comput. Soc. Syst.*, vol. 11, no. 2, pp. 456–467, Apr. 2024, doi: 10.48550/arXiv.2010.12783.

[9] M. Chen, Z. Wei, Z. Huang, B. Ding, and Y. Li, "Simple and deep graph convolutional networks," in *Proc. 37th Int. Conf. Mach. Learn. (ICML)*, 2020, pp. 1725–1735, doi: 10.48550/arXiv.2007.02133.

[10] J. Gasteiger, A. Bojchevski, and S. Günnemann, "Predict then propagate: Graph neural networks meet personalized PageRank," in *Proc. 7th Int. Conf. Learn. Represent. (ICLR)*, 2019, doi: 10.48550/arXiv.1810.05997.

[11] J. Zhu, Y. Yan, L. Zhao, M. Heimann, L. Akoglu, and D. Koutra, "Beyond homophily in graph neural networks: Current limitations and effective designs," in *Proc. 34th Int. Conf. Neural Inf. Process. Syst. (NeurIPS)*, 2020, pp. 7793–7804, doi: 10.48550/arXiv.2006.11468.

[12] S. Abu-El-Haija, B. Perozzi, N. Kapoor, N. Alipourfard, K. Lerman, H. Harutyunyan, G. V. Steeg, and A. Galstyan, "MixHop: Higher-order graph convolutional architectures via sparsified neighborhood mixing," in *Proc. 36th Int. Conf. Mach. Learn. (ICML)*, 2019, pp. 21–29, doi: 10.48550/arXiv.1905.00067.

[13] B. Perozzi, R. Al-Rfou, and S. Skiena, "DeepWalk: Online learning of social representations," in *Proc. 20th ACM SIGKDD Int. Conf. Knowl. Discov. Data Mining (KDD)*, 2014, pp. 701–710, doi: 10.1145/2623330.2623732.

پاورقی‌ها:

[1] Embedding
[2] Adaptive Sampling
[3] Contrastive
[4] Attention based Message Passing
[5] Bayesian Optimization
[6] Random Walks
[7] Downstream Tasks
[8] Matrix Factorization
[9] Over smoothing
[10] Multi Head
[11] Self Attention
[12] Over-Smoothing
[13] Multi Modal