

# Diversidade na Construção de Vizinhanças para Redes Convolucionais de Grafos em Classificação de Imagens

Diego Giaretta de Paulo<sup>1</sup>, Lucas Pascotti Valem<sup>1</sup>

<sup>1</sup>Universidade de São Paulo (USP)  
Instituto de Ciências Matemáticas e de Computação (ICMC)  
São Carlos, SP — Brasil

giaretta@usp.br, lucas@icmc.usp.br

**Abstract.** *The growing volume of available images demands effective classification methods. Many deep learning models rely on large labeled datasets, which are costly to obtain. Semi-supervised learning emerges as a promising alternative, and graph convolutional networks (GCNs) exploit relationships between labeled and unlabeled samples. However, the common approach for images employs graphs based solely on similarity, which restricts the variety of neighborhoods. This master's research investigates strategies for constructing neighborhoods with diversity for GCNs, under the hypothesis that more diverse neighborhoods favor learning. We propose the BRID-G method, which presents promising preliminary results.*

**Resumo.** *O crescente volume de imagens disponíveis exige métodos eficazes de classificação. Muitos modelos de aprendizado profundo dependem de grandes conjuntos de dados rotulados, cuja obtenção é custosa. O aprendizado semi-supervisionado surge como alternativa promissora, e as redes convolucionais de grafos (GCNs) exploram relações entre amostras rotuladas e não rotuladas. Contudo, a abordagem comum para imagens emprega grafos baseados apenas em similaridade, o que pode restringir a variedade das vizinhanças. Este mestrado investiga a construção de grafos com diversidade para GCNs, sob a hipótese de que vizinhanças mais diversas favorecem o aprendizado. Propõe-se o método BRID-G, que apresenta resultados preliminares promissores.*

**Informações Gerais.** **Nível:** Mestrado. **Aluno:** Diego Giaretta de Paulo. **Orientador:** Lucas Pascotti Valem. **Programa:** Programa de Pós-Graduação em Ciências de Computação e Matemática Computacional (PPG-CCMC) da Universidade de São Paulo. **Admissão:** Agosto 2025. **Defesa prevista:** Agosto 2027. **Etapas concluídas:** disciplinas obrigatórias do primeiro semestre do programa.

## 1. Introdução

O grande crescimento no volume de dados criou a necessidade de métodos capazes de automatizar tarefas como classificação e recuperação de dados. Grande parte dessas abordagens depende hoje de modelos de aprendizado de máquina, área atualmente dominada por técnicas de aprendizado profundo [Awais et al. 2025]. Apesar de sua popularidade, muitos desses métodos exigem grandes volumes de dados rotulados para o treinamento, e anotar dados costuma ser uma tarefa demorada e custosa, pois frequentemente requer o uso de especialistas.

Nesse cenário, as Redes Convolucionais de Grafos (GCNs) [Kipf and Welling 2017] se apresentam como uma alternativa promissora, pois podem ser empregadas em contextos semi-supervisionados, aprendendo tanto com

dados anotados quanto não anotados. Diferentemente das Redes Neurais Convolucionais (CNNs) [Awais et al. 2025], as GCNs conseguem aprender mesmo com poucos dados anotados, graças à sua capacidade de explorar a informação estrutural do grafo, indo além do espaço euclidiano.

No entanto, ao contrário da maioria dos classificadores, as GCNs precisam de duas entradas: vetores de características (*features*) e um grafo. Em domínios como redes de citações, o grafo já existe, mas em dados visuais ele precisa ser construído, o que levanta uma questão relevante: *como modelar grafos de imagens para GCNs?* Uma alternativa frequente é extrair vetores de características por aprendizado profundo, de modo que cada imagem seja um nó e as imagens mais semelhantes sejam conectadas entre si. Duas abordagens muito utilizadas são o grafo kNN, que conecta as  $k$  imagens mais similares, e o grafo kNN recíproco, que conecta apenas as imagens que são vizinhas mútuas entre os  $k$  elementos mais próximos [Valem et al. 2023]. Ambas, porém, baseiam-se na similaridade, ignorando a diversidade, ou seja, a diferença, variância ou heterogeneidade entre os elementos. A diversidade é igualmente importante [Carbonell and Goldstein 1998], pois pode favorecer elementos distintos e potencializar a generalização do modelo [Figuerêdo et al. 2025]. Além disso, vizinhanças excessivamente homogêneas tendem a acentuar o *oversmoothing*, fenômeno em que as representações dos nós se tornam progressivamente indistinguíveis [Oono and Suzuki 2020].

Em domínios não visuais, a importância da diversidade para redes neurais de grafos (GNNs) já foi reconhecida: trabalhos em previsão de séries temporais multivariadas [Xu et al. 2025] e em sistemas de recomendação [Gao et al. 2023] mostram que grafos baseados apenas em similaridade acumulam vizinhos redundantes, limitando a informação propagada pela rede. No entanto, até onde sabemos, poucos trabalhos exploram essas hipóteses em tarefas de classificação de imagens com GNNs.

Esta pesquisa de mestrado parte da hipótese de que incorporar a diversidade, e não apenas a similaridade, na construção do grafo pode aumentar a eficácia da classificação realizada pelas GCNs. Para isso, propõe-se o BRID-G (*Better Results with Influence Diversification for Graphs*), uma adaptação do método BRID [Santos et al. 2013], originalmente concebido para recuperação de dados em bancos de dados, para a construção do grafo da GCN. Trata-se de uma estratégia que poda arestas mutuamente redundantes dentro de uma vizinhança kNN ordenada, explorando a diversidade. Os resultados preliminares são promissores, mostrando-se superiores ou comparáveis aos de outros métodos.

## 2. Abordagem Proposta: BRID-G

Seja  $G = (V, E)$  um grafo simétrico cujos  $n$  vértices correspondem a imagens com descritores  $x_i \in \mathbb{R}^d$ , adjacência normalizada  $\tilde{A}$ , rótulos observados em  $V_\ell \subset V$  e  $\mathcal{N}_k(q)$  denotando os  $k$  vizinhos mais próximos de  $q$ . Embora  $\mathcal{N}_k(q)$  seja um conjunto, por simplicidade de notação assume-se, ao indexá-lo ou tomar prefixos, que seus elementos estão ordenados por distância não decrescente em relação a  $q$ .

Os classificadores *Simple Graph Convolution* (SGC) [Wu et al. 2019] e *Approximate Personalized Propagation of Neural Predictions* (APPNP) [Gasteiger et al. 2019] dependem de  $\tilde{A}$ . Dessa forma, alterar  $E$  modifica a geometria espectral e a fronteira aprendida. Quando a seleção kNN concentra vizinhos muito similares,  $\mathcal{N}_k(q)$  pode se tornar redundante, limitando a diversidade da informação propagada e acentuando potencialmente o *oversmoothing* [Oono and Suzuki 2020, Alon and Yahav 2021]. O BRID-G substitui a seleção puramente baseada em similaridade por uma poda orientada à diversidade, mapeando  $(X, k, \text{hiperparâmetros})$  para  $E$  em três estágios: (1) filtragem de influência, que poda redundâncias dentro do top- $k$ ; (2) triangulação, que reintroduz coesão

local de forma controlada; e (3) filtragem estrutural, que exige reciprocidade e concor-  
dância entre listas ordenadas. A Fig. 1 resume o *pipeline* experimental, enquanto a Fig. 2  
ilustra a poda por influência em 2D. **A construção do grafo apoia-se em três definições:**




Figura 1. Diagrama de etapas que compõem o BRID-G.




Figura 2. Ilustração das etapas de inclusão de arestas por influência do BRID-G.

**Definição 1 (Intensidade de influência)** Dada a distância euclidiana  $d_2$ , a intensidade de influência entre dois vértices  $x_u, x_v \in V$  é

$$I(x_u, x_v) = \frac{1}{d_2(x_u, x_v)}, \quad I(x_v, x_v) = 0. \quad (1)$$

Pares mais próximos exercem influência mais forte entre si.

**Definição 2 (Dominância bilateral)** Um vértice  $x_i$  domina  $x_j$  com relação à imagem de referência  $x_q$ , denotado  $x_i \succ_{x_q} x_j$ , quando

$$x_i \succ_{x_q} x_j \iff I(x_i, x_j) \geq I(x_i, x_q) \wedge I(x_j, x_i) \geq I(x_j, x_q). \quad (2)$$

Intuitivamente, se dois candidatos se influenciam mais entre si do que influenciam  $x_q$ , um deles é redundante na vizinhança de  $x_q$ .

**Definição 3 (Similaridade entre listas ordenadas — RBO)** *Sejam  $\Pi_{x_i}$  e  $\Pi_{x_j}$  as listas dos  $k$  vizinhos mais próximos de  $x_i$  e  $x_j$ , ordenadas por distância não decrescente. A medida Rank-Biased Overlap (RBO) [Webber et al. 2010] quantifica a sobreposição entre listas ordenadas, atribuindo maior peso às posições iniciais. Truncada na profundidade  $k$  e com persistência  $p \in (0, 1)$ , ela é definida como:*

$$\text{RBO}(\Pi_{x_i}, \Pi_{x_j}, k, p) = (1 - p) \sum_{d=1}^k p^{d-1} \cdot \frac{|\Pi_{x_i}[1:d] \cap \Pi_{x_j}[1:d]|}{d}, \quad (3)$$

em que  $\Pi[1:d]$  denota o prefixo de tamanho  $d$  da lista. O peso exponencialmente decrescente privilegia a concordância nas posições mais altas do ranking.

O Algoritmo 1 formaliza a construção completa do conjunto de arestas  $E$ . A função FILTRAR (linhas 1–6) atua como critério final de aceitação: toda aresta, seja ela oriunda do Estágio 1 ou do Estágio 2, só é adicionada ao conjunto  $E$  se satisfizer reciprocidade e concordância de listas.

---

**Algoritmo 1:** Construção do grafo BRID-G.

---

**Entrada:**  $X \in \mathbb{R}^{n \times d}$ , vizinhança  $k$ , métrica  $d_2$ , obrigatórios  $m$ , similaridade sim ( $\text{RBO}_{p=0,9}$ ), limiar  $\tau$ , triangulação  $t$

**Saída:** Grafo  $G = (V, E)$

**Função** Filtrar( $x_a, x_b$ ):

```

1  se  $x_a \notin \mathcal{N}_k(x_b)$  ou  $x_b \notin \mathcal{N}_k(x_a)$  então
2      retornar Falso // reciprocidade
3
4  se  $\text{sim}(\Pi_{x_a}, \Pi_{x_b}) < \tau$  então
5      retornar Falso // concordância (Def. 3)
6  retornar Verdadeiro

7   $E \leftarrow \emptyset$ 
8  para cada imagem  $x_q \in V$  faça
9      Computar  $\mathcal{N}_k(x_q)$  ordenado por  $d_2(x_q, \cdot)$ 
10      $\mathcal{A} \leftarrow \emptyset$  // vizinhos aceitos globais
11     /* Estágio 1 -- Filtragem de influência (Defs. 1-2; cf. Fig. 2) */
12     para cada âncora  $x_i \in \mathcal{N}_k(x_q)$  em ordem de proximidade faça
13          $R_i \leftarrow \emptyset$ 
14         para cada candidato  $x_j \in \mathcal{N}_k(x_q) \setminus \{x_i\}$  faça
15             se  $x_i \succ_{x_q} x_j$  então
16                 continuar // dominado pela âncora
17             se  $\exists x_r \in R_i : x_r \succ_{x_q} x_j$  então
18                 continuar // dominado por aceito
19              $R_i \leftarrow R_i \cup \{x_j\}$ 
20      $\mathcal{A} \leftarrow \bigcup_i R_i$ 
21     /* Conexões obrigatórias -- top- $m$  sem filtro de dominância */
22     para  $\ell = 1$  to  $m$  faça
23          $\mathcal{A} \leftarrow \mathcal{A} \cup \{\mathcal{N}_k(x_q)[\ell]\}$ 
24     /* Estágio 3 -- Filtragem estrutural */
25     para cada  $x_j \in \mathcal{A}$  faça
26         se Filtrar( $x_q, x_j$ ) então
27              $E \leftarrow E \cup \{(x_q, x_j)\}$ 
28     /* Estágio 2 -- Triangulação */
29     Eleger os primeiros  $t$  vizinhos de  $\mathcal{A}$ 
30     para cada par  $\{x_a, x_b\} \subset \mathcal{A}[1..t]$  faça
31         se Filtrar( $x_a, x_b$ ) então
32              $E \leftarrow E \cup \{(x_a, x_b)\}$ 
33 retornar  $G = (V, E)$ 

```

---

No Estágio 1 (linhas 11–19), cada âncora  $x_i$  avalia independentemente quais candidatos não são redundantes, construindo uma lista local  $R_i$ : um candidato  $x_j$  é descartado

se for dominado pela âncora (linha 14, Definição 2) ou por algum vizinho já aceito (linha 16); a fusão de múltiplas âncoras (linha 19) atenua o viés de uma varredura gulosa única [Carbonell and Goldstein 1998]. A Fig. 2 ilustra esse processo com  $k = 7$ : as âncoras produzem  $R_1, R_2, R_3$ , cuja união  $\{x_1, x_3, x_4, x_7\}$  retém vizinhos complementares. O parâmetro  $m$  (linha 20) injeta os  $m$  vizinhos mais próximos em  $\mathcal{A}$  sem o filtro de dominância (embora ainda sujeitos à filtragem estrutural do Estágio 3), calibrando a tensão entre diversidade e aderência ao *ranking* de similaridade. No **Estágio 3** (linhas 22 e 1–6), toda aresta candidata é submetida à função FILTRAR: primeiro a reciprocidade ( $x_q \in \mathcal{N}_k(x_j)$  e  $x_j \in \mathcal{N}_k(x_q)$ ) e, em seguida, a concordância de listas ( $\text{sim} \geq \tau$ , cf. Definição 3), sendo  $\text{sim}$  a própria  $\text{RBO}_{p=0,9}$ . No **Estágio 2** (linha 25), os primeiros  $t$  vizinhos aceitos de  $x_q$  formam triângulos locais sujeitos aos mesmos critérios, fortalecendo a coesão sem recuperar a clique densa do kNN.

Em síntese, os hiperparâmetros do BRID-G são  $k$  (tamanho da vizinhança candidata), a métrica de distância  $d_2$ ,  $m$  (conexões obrigatórias),  $\tau$  (limiar de concordância) e  $t$  (extensão da triangulação). Os *baselines* kNN simples e kNN recíproco usam os mesmos descritores  $X$ .

### 3. Avaliação Experimental

Foram utilizadas três bases de imagens: Flowers-17 [Nilsback and Zisserman 2006], com 17 espécies de flores e 80 imagens por espécie (total de 1.360); Corel-5k [Liu and Yang 2013], com 50 categorias de objetos diversos e 100 imagens cada (total de 5.000); e Oxford-IIIT Pets [Parkhi et al. 2012], com 7.349 imagens de 37 raças de cães e gatos. De cada base, extraíram-se vetores de características por meio de dois modelos de aprendizado profundo pré-treinados na ImageNet: ResNet-152 e ViT-B/16 [Awais et al. 2025].

Para propósito de comparação, foram considerados dois *baselines* preliminares: os grafos kNN e kNN recíproco com distância euclidiana e  $k = 40$ , valor escolhido para manter consistência com trabalhos anteriores [Valem et al. 2023]; o BRID-G adota  $k = 40$ ,  $m = 5$ ,  $\tau = 0,1$ ,  $t = 5$  e persistência  $p = 0,9$  em todas as bases. Como classificadores, adotam-se SGC e APPNP, este último com  $\alpha = 0,5, 0,1$  e  $0,3$  para Flowers-17, Corel-5k e Oxford-IIIT Pets, respectivamente. O protocolo experimental consiste na média de 5 execuções com validação cruzada de 10 *folds*, sempre com 10% das amostras para treino e 90% para teste, impondo um regime de poucos dados. Reporta-se a acurácia média  $\pm$  desvio padrão. Os valores de  $\Delta$  indicam o ganho relativo (%) em relação aos *baselines*.

Com o objetivo de avaliar a contribuição individual de cada componente, a Tabela 1 apresenta um estudo de ablação do método BRID-G utilizando a base Flowers-17, o extrator ResNet e a rede SGC. A análise demonstra um ganho progressivo de acurácia à medida que cada nova etapa é incorporada ao modelo.

**Tabela 1. Ablação do BRID-G na base Flowers, extrator ResNet e modelo SGC.**  
BRID-G<sup>b</sup> denota a versão base, apenas com a filtragem de influência.

| Etapa               | Acur. (%) $\pm$ dp | $\Delta_{etapa}$ | $\Delta_{BRID-G}$ |
|---------------------|--------------------|------------------|-------------------|
| BRID-G <sup>b</sup> | 81,27 $\pm$ 1,53   | —                | —                 |
| + Recíproco         | 83,46 $\pm$ 1,67   | +2,69%           | +2,69%            |
| + RBO               | 84,44 $\pm$ 0,96   | +1,17%           | +3,90%            |
| + Triangulação      | 84,60 $\pm$ 1,22   | +0,19%           | +4,10%            |
| + Obrigatórios      | 85,06 $\pm$ 0,93   | +0,54%           | +4,66%            |

Por fim, comparamos os ganhos do nosso método sobre os grafos kNN e kNN recíproco na Tabela 2, o que é feito para cada uma das bases de imagens, extratores e redes. O BRID-G iguala ou supera o recíproco na maioria dos cenários, com ganhos mais expressivos para o ViT, o que sugere um benefício estrutural da diversificação de vizinhanças nesses resultados preliminares.

**Tabela 2. Acurácia (%) do BRID-G em comparação a kNN e kNN Recíproco.**

| Base     | Extrator | Modelo | kNN              | kNN Recíp.                         | BRID-G                             | $\Delta_{kNN}$ | $\Delta_{Rec.}$ |
|----------|----------|--------|------------------|------------------------------------|------------------------------------|----------------|-----------------|
| Flowers  | ViT      | SGC    | 92,96 $\pm$ 1,04 | 96,90 $\pm$ 0,48                   | <b>97,38 <math>\pm</math> 0,33</b> | +4,75%         | +0,49%          |
|          |          | APNP   | 96,82 $\pm$ 0,88 | 97,92 $\pm$ 0,48                   | <b>98,02 <math>\pm</math> 0,35</b> | +1,24%         | +0,10%          |
|          | ResNet   | SGC    | 80,74 $\pm$ 0,78 | 84,38 $\pm$ 1,80                   | <b>85,06 <math>\pm</math> 0,93</b> | +5,34%         | +0,80%          |
|          |          | APNP   | 84,58 $\pm$ 1,04 | 85,74 $\pm$ 1,22                   | <b>86,27 <math>\pm</math> 1,22</b> | +2,00%         | +0,62%          |
| Corel-5k | ViT      | SGC    | 93,44 $\pm$ 0,46 | 95,40 $\pm$ 0,33                   | <b>95,44 <math>\pm</math> 0,49</b> | +2,13%         | +0,04%          |
|          |          | APNP   | 87,94 $\pm$ 1,10 | 91,84 $\pm$ 1,01                   | <b>92,22 <math>\pm</math> 1,04</b> | +4,88%         | +0,42%          |
|          | ResNet   | SGC    | 90,22 $\pm$ 0,48 | 91,95 $\pm$ 0,88                   | <b>92,08 <math>\pm</math> 1,01</b> | +2,06%         | +0,14%          |
|          |          | APNP   | 90,48 $\pm$ 0,56 | 92,12 $\pm$ 0,69                   | <b>92,48 <math>\pm</math> 0,69</b> | +2,20%         | +0,39%          |
| Pets     | ViT      | SGC    | 84,85 $\pm$ 1,14 | 88,18 $\pm$ 0,93                   | <b>88,22 <math>\pm</math> 0,96</b> | +3,97%         | +0,04%          |
|          |          | APNP   | 84,57 $\pm$ 1,95 | 86,69 $\pm$ 0,84                   | <b>87,00 <math>\pm</math> 1,20</b> | +2,88%         | +0,35%          |
|          | ResNet   | SGC    | 88,60 $\pm$ 0,84 | <b>90,02 <math>\pm</math> 0,76</b> | 89,75 $\pm$ 0,65                   | +1,29%         | -0,31%          |
|          |          | APNP   | 89,95 $\pm$ 0,94 | <b>90,45 <math>\pm</math> 0,99</b> | 90,43 $\pm$ 0,93                   | +0,53%         | -0,02%          |

#### 4. Conclusão

Os resultados preliminares desta pesquisa de mestrado mostram que o BRID-G propõe uma nova forma de construir vizinhanças em grafos de imagens, substituindo a seleção puramente baseada em similaridade por uma poda orientada à diversidade. Nos casos avaliados, o BRID-G iguala ou supera o kNN recíproco na maioria dos casos, possível indício de que vizinhanças mais diversas produzem representações mais discriminativas. A análise por etapas também indica que cada estágio contribui positivamente para a acurácia final. Como continuidade, pretende-se avaliar outros modelos de redes de grafos, investigar maneiras alternativas de considerar a diversidade, utilizar indicadores específicos para avaliar o *oversmoothing* e estender a avaliação a cenários de recuperação de imagens.

#### Agradecimentos

Este trabalho foi realizado com apoio da Fundação de Amparo à Pesquisa do Estado de São Paulo (FAPESP, processo nº 2025/10602-5), da Universidade de São Paulo (Portaria PRPI nº 1032, “Apoio aos Novos Docentes”) e da Coordenação de Aperfeiçoamento de Pessoal de Nível Superior - Brasil (CAPES) – Código de Financiamento 001.

#### Declaração de Uso de Inteligência Artificial

Foram utilizados modelos generativos (Claude e ChatGPT) exclusivamente para revisar e aprimorar a clareza do texto.

#### Referências

- Alon, U. and Yahav, E. (2021). On the bottleneck of graph neural networks and its practical implications. In *International Conference on Learning Representations (ICLR)*.
- Awais, M., Naseer, M., Khan, S., Anwer, R. M., Cholakkal, H., Shah, M., Yang, M.-H., and Khan, F. S. (2025). Foundation models defining a new era in vision: A survey and outlook. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 47(4):2245–2264.

- Carbonell, J. G. and Goldstein, J. (1998). The use of MMR, diversity-based reranking for reordering documents and producing summaries. In *Proceedings of the 21st Annual International ACM SIGIR Conference on Research and Development in Information Retrieval*, pages 335–336. ACM.
- Figuerêdo, J. S. L., Maia, A. L. M., and Calumby, R. T. (2025). GDRF: An innovative graph-based rank fusion method for enhancing diversity in image metasearch. *Journal of Information and Data Management*, 16(1):21–27.
- Gao, C., Zheng, Y., Li, N., Li, Y., Qin, Y., Piao, J., Quan, Y., Chang, J., Jin, D., He, X., and Li, Y. (2023). A survey of graph neural networks for recommender systems: Challenges, methods, and directions. *ACM Transactions on Recommender Systems*, 1(1).
- Gasteiger, J., Bojchevski, A., and Günnemann, S. (2019). Predict then propagate: Graph neural networks meet personalized pagerank. In *International Conference on Learning Representations (ICLR)*.
- Kipf, T. N. and Welling, M. (2017). Semi-supervised classification with graph convolutional networks. In *International Conference on Learning Representations (ICLR)*.
- Liu, G.-H. and Yang, J.-Y. (2013). Content-based image retrieval using color difference histogram. *Pattern Recognition*, 46(1):188 – 198.
- Nilsback, M.-E. and Zisserman, A. (2006). A visual vocabulary for flower classification. In *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, pages 1447–1454.
- Oono, K. and Suzuki, T. (2020). Graph neural networks exponentially lose expressive power for node classification. In *International Conference on Learning Representations (ICLR)*.
- Parkhi, O. M., Vedaldi, A., Zisserman, A., and Jawahar, C. V. (2012). Cats and dogs. In *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, pages 3498–3505.
- Santos, L. F. D., Oliveira, W. D., Ferreira, M. R. P., Traina, A. J. M., and Traina, C. (2013). Parameter-free and domain-independent similarity search with diversity. In *Proceedings of the 25th International Conference on Scientific and Statistical Database Management, SSDBM '13*, New York, NY, USA. Association for Computing Machinery.
- Valem, L. P., Pedronette, D. C. G., and Latecki, L. J. (2023). Graph convolutional networks based on manifold learning for semi-supervised image classification. *Computer Vision and Image Understanding*, 227:103618.
- Webber, W., Moffat, A., and Zobel, J. (2010). A similarity measure for indefinite rankings. *ACM Transactions on Information Systems*, 28(4):20:1–20:38.
- Wu, F., Souza, A., Zhang, T., Fifty, C., Yu, T., and Weinberger, K. (2019). Simplifying graph convolutional networks. In *International Conference on Machine Learning (ICML)*.
- Xu, J., Chen, G., Lu, J., and Lin, Y. (2025). Graph neural networks with diversity-aware neighbor selection and dynamic multi-scale fusion for multivariate time series forecasting. *arXiv preprint arXiv:2509.23671*.