Влияние способа построения матрицы смежности на обобщающую способность графовых нейронных сетей при анализе сигналов носимых датчиков

Л. С. Сидоров*, А. И. Майсурадзе‡

В работе проверяется, как способ задания матрицы смежности влияет на macro-F1 графовой нейронной сети. На UCI HAR по 20 парным запускам граф по метаданным каналов сравнивается с дополнением той же степени, с графом без рёбер и с гибридным дообучением. Средняя разность с дополнением составляет 1,5–1,9 п. п. и после поправки Холма значима при всех долях обучающей выборки. Разность с графом без рёбер значима при 5 и 10%. Гибридное дообучение значимо хуже фиксированной матрицы при 10 и 100%. Разброс этой разности внутри одной подвыборки больше, чем между подвыборками. На отрезке начальных графов при полной выборке провала нет.

Ключевые слова: графовые нейронные сети, матрица смежности, многомерные временные ряды, обобщающая способность, распознавание активности.

1. Постановка задачи

Рассматриваются многомерные временные ряды, у каналов которых известны метаданные связи. Наблюдение — матрица $X \in \mathbb{R}^{N\times T}$, каналы — вершины графа. Слой типа GIN [1] вычисляет $Z = \mathrm{ReLU}((X + AX)W)$, где W — общая для вершин свёртка по времени; затем свёртка 1×1 по

* *Сидоров Леонид Станиславович* — аспирант каф. математических методов прогнозирования ф-та ВМК МГУ, e-mail: leon.sidorov@gmail.com, ORCID: 0009-0000-6060-252X.

Sidorov Leonid Stanislavovich — PhD student, Department of Mathematical Methods of Forecasting, Faculty of Computational Mathematics and Cybernetics, Lomonosov Moscow State University.

‡ *Майсурадзе Арчил Ивериевич* — канд. физ.-мат. наук, доцент каф. математических методов прогнозирования ф-та ВМК МГУ, e-mail: maysuradze@cs.msu.ru, ORCID: 0000-0002-1757-556X.

Maysuradze Archil Iverievich — Candidate of Physical and Mathematical Sciences, Associate Professor, Department of Mathematical Methods of Forecasting, Faculty of Computational Mathematics and Cybernetics, Lomonosov Moscow State University.

Опубликовано на условиях лицензии CC-BY 4.0
Published under CC-BY 4.0

каналам, две временные свёртки и линейный классификатор. Строки априорной матрицы A_0 нормируются до обучения.

Для девяти каналов смартфона (три датчика на три оси) граф метаданных A_{meta} соединяет каналы с общим датчиком или общей осью: степень каждой вершины равна 4. Контроль A_{anti} — дополнение той же степени: ребро проводится, только если различаются и датчик, и ось. Сравниваются три режима. Фиксированный: $A = A_0$ не меняется. Гибридный: A — свободная матрица $N \times N$, инициализированная A_0 и обновляемая тем же шагом Adam, что и веса сети; симметрия, неотрицательность и нормировка строк при обучении не сохраняются. Обучение с нуля отличается лишь инициализацией Ксавье. Начальное приближение на отрезке между ними — $A(\theta) = (1-\theta)A_{\text{meta}} + \theta A_{\text{anti}}$; при $\theta = 1/2$ получается нормированный полный граф.

На электроэнцефалограмме граф по координатам электродов давал более высокое качество, чем более плотный случайный граф [3], а гибридный способ — чем фиксированная матрица [2]. Плотность там не уравнивалась. Здесь при равной степени вершин проверяются три утверждения о средней macro-F1: она выше у графа метаданных, чем у дополнения и у графа без рёбер; гибридный способ не хуже фиксированной матрицы; зависимость от θ имеет провал при $\theta = 1/2$.

2. Данные и протокол

Набор UCI HAR [4]: окна по 128 отсчётов с перекрытием 50%, девять каналов, шесть активностей. Четыре из 21 обучающего участника отложены для выбора модели, тест — 9 остальных. При доле $f < 1$ seed запуска берёт внутри каждого класса долю f окон без возвращения, без стратификации по участникам, и тем же генератором перемешивает батчи. Подвыборка и порядок батчей общие для вариантов одного запуска. Основные сравнения — 20 таких запусков. Дополнительно при 5 и 10% взяты 4 подвыборки и на каждой 5 seed обучения. Долям 5, 10, 25 и 100% отвечают 600, 300, 120 и 30 эпох (Adam, шаг 10^{-3}, батч 128). Разности сравниваются парным t-критерием; значимость — поправка Холма по трём строкам табл. 1. Отрезок $\theta = 0; 0{,}1; \ldots; 1$ пройден при 100% окон, оба режима, по 5 запусков.

3. Результаты

По табл. 1 разность с дополнением значима при всех долях, с графом без рёбер — при 5 и 10%, гибрид хуже фиксированной матрицы при 10 и 100%.

Таблица 1: Разность macro-F1, п. п.: среднее и 95% интервал парного t-критерия, $n = 20$. $*$ — значимо после Холма, $m = 3$.

сравнение	5%	10%	25%	100%
метаданные / дополнение	$+1{,}5\,[0{,}5;\,2{,}4]^*$	$+1{,}5\,[0{,}7;\,2{,}4]^*$	$+1{,}9\,[1{,}1;\,2{,}7]^*$	$+1{,}5\,[0{,}8;\,2{,}2]^*$
метаданные / без рёбер	$+1{,}6\,[0{,}6;\,2{,}6]^*$	$+1{,}1\,[0{,}3;\,2{,}0]^*$	$+0{,}7\,[-0{,}1;\,1{,}5]$	$+0{,}3\,[-0{,}6;\,1{,}3]$
гибридный / фиксир.	$-0{,}3\,[-1{,}0;\,0{,}4]$	$-0{,}7\,[-1{,}2;\,-0{,}2]^*$	$-0{,}3\,[-0{,}7;\,0{,}1]$	$-0{,}6\,[-1{,}0;\,-0{,}2]^*$

При 5 и 10% на 4 подвыборках по 5 seed стандартное отклонение разности «метаданные минус дополнение» внутри подвыборки равно 0,015 и 0,017, а между средними подвыборок — 0,005 и 0,008. Отрезок по θ строился только при 100% окон: macro-F1 лежит в 0,886–0,905, провала при $\theta = 1/2$ нет.

4. Заключение

На UCI HAR граф метаданных лучше своего дополнения той же степени при всех долях обучающей выборки; это не сводится к степени вершин и не объясняется выбором конкретной подвыборки окон. Выигрыш перед графом без рёбер есть при 5 и 10%. Гибридное дообучение не лучше фиксированной матрицы. На полной выборке провала вдоль отрезка начальных графов нет. На другие графы и на электроэнцефалограмму результат не переносится.

Список литературы

[1] K. Xu, W. Hu, J. Leskovec, S. Jegelka, “How powerful are graph neural networks?”, *International Conference on Learning Representations*, 2019, arXiv: 1810.00826.

[2] L. Sidorov, A. Maysuradze, “The influence of graph construction methods on the generalization ability of graph neural networks in neurophysiological EEG analysis”, *Intellectualization of information processing (IOI-2024)* (Grodno, September 23–27, 2024), 2024, 46–47.

[3] L. S. Sidorov, A. I. Maysuradze, “The impact of enriching electroencephalogram in spatial metadata on interpretability and generalization ability of graph neural networks”, *Pattern Recognition and Image Analysis*, **34**:4 (2024), 1255–1263. DOI: 10.1134/S1054661824701323.

[4] D. Anguita, A. Ghio, L. Oneto, X. Parra, J. L. Reyes-Ortiz, “A public domain dataset for human activity recognition using smartphones”, *Proceedings of the 21st European Symposium on Artificial Neural Networks (ESANN 2013)*, 2013, 437–442.

Статья поступила 13 октября 2026 г.

The influence of adjacency matrix construction on the generalization ability of graph neural networks in wearable sensor signal analysis

L. S. Sidorov, A. I. Maysuradze

The paper tests how the choice of the adjacency matrix affects the macro-F1 of a graph neural network. On UCI HAR, over 20 paired runs, a channel-metadata graph is compared with its equal-degree complement, a graph without edges, and hybrid fine-tuning. The mean difference from the complement is 1.5–1.9 percentage points and is significant after the Holm correction at every training fraction. The difference from the graph without edges is significant at 5 and 10%. Hybrid fine-tuning is significantly worse than the fixed matrix at 10 and 100%. The spread of the difference within one subsample exceeds the spread between subsamples. A sweep of initial graphs on the full training set shows no dip.

Keywords: graph neural networks, adjacency matrix, multivariate time series, generalization ability, activity recognition.

References

[1] K. Xu, W. Hu, J. Leskovec, S. Jegelka, "How powerful are graph neural networks?", *International Conference on Learning Representations*, 2019, arXiv: 1810.00826.

[2] L. Sidorov, A. Maysuradze, "The influence of graph construction methods on the generalization ability of graph neural networks in neurophysiological EEG analysis", *Intellectualization of information processing (IOI-2024)* (Grodno, September 23–27, 2024), 2024, 46–47.

[3] L. S. Sidorov, A. I. Maysuradze, "The impact of enriching electroencephalogram in spatial metadata on interpretability and generalization ability of graph neural networks", *Pattern Recognition and Image Analysis*, **34**:4 (2024), 1255–1263. DOI: 10.1134/S1054661824701323.

[4] D. Anguita, A. Ghio, L. Oneto, X. Parra, J. L. Reyes-Ortiz, "A public domain dataset for human activity recognition using smartphones", *Proceedings of the 21st European Symposium on Artificial Neural Networks (ESANN 2013)*, 2013, 437–442.

Received on October 13, 2026