

# Multi-Relational Graph Attention Network for Social Relationship Inference from Human Mobility Data

Moritz Kowalski

Goethe-Universität Frankfurt am Main

16. Juli 2025

# Agenda

- 1 Motivation & Problemstellung
- 2 Grundidee von MRGAN
- 3 Modellarchitektur
- 4 Experimente & Ergebnisse
- 5 Diskussion & Ausblick

- LBSN-Dienste wie Foursquare (Yelp), Gowalla (Facebook) erzeugen riesige Mobilitätsdaten
- Viele soziale Verbindungen sind nicht explizit sichtbar
- Mobilitätsmuster lassen Rückschlüsse auf soziale Nähe zu
- Anwendungen: Freundschaftsvorhersage, personalisierte Empfehlungen, Werbung

## Mobility Social Relationship Inference:

- Gegeben: Check-in-Daten + einige bekannte Freundschaften
- Gesucht: Vorhersage, ob zwei Personen befreundet sind
- Herausforderung: viele Beziehungen nur indirekt erkennbar
- Lösung: Nutzung auch indirekter Informationen

## MRGAN = Multi-Relational Graph Attention Network

- Neuronales Netz auf multi-relationalem Graph
- Vorhersage sozialer Beziehungen
- Nutzt Mobilitätsdaten + Attention

*Beispiel: Sind zwei Personen befreundet, wenn sie ähnliche Orte besuchen?*

## Vier Typen von Beziehungen:


- **Direkt:** Freundschaft, Treffen
- **Indirekt:** gleiche Orte, ähnliche Präferenzen

## Beispiel:

- Freundschaft: Person A und B sind direkt befreundet
- Treffen: Person A und B sind gleichzeitig am selben Ort
- Gleiche Orte: Person A und B besuchen oft denselben Ort
- Ähnliche Präferenzen: Person A und B besuchen Orte, die oft zusammen besucht werden


# Modellarchitektur von MRGAN

- Heterogener Mobilität Graph (User, POIs, Check-ins, Co-Occurrence)
- Konstruktion eines Multi-Relationalen Graphen (4 Beziehungstypen)
- Pro Relation: Lernen von Embeddings mit Influence Attention
- Cross-Relation Aggregator: kombiniert die Embeddings
- Vorhersage durch Ähnlichkeit der finalen Embeddings



- Für jede Relation (z.B. Meeting, Freundschaft, ...) wird ein separater Graph gebildet
- Innerhalb dieses Teilgraphen: GAT (Graph Attention Network)
- Attention bestimmt, welche Nachbarn in dieser Relation wichtig sind
- Ergebnis: Ein Nutzer-Embedding pro Relation  $h_i^r$
- Motivation: Ein Nutzer kann in einer Relation sehr aktiv sein – in einer anderen nicht

# Relation: Beispiel Meeting-Subgraph



*Relation-spezifisches GAT: Einfluss von Nachbarn mit Attention-Gewichten.*

# Cross-Relation Embedding Aggregator


- Jeder Nutzer hat 4 Embeddings:  $h_i^F$ ,  $h_i^M$ ,  $h_i^{PP}$ ,  $h_i^{CP}$
- Zweiter Attention-Mechanismus bestimmt, welche Relation wie stark zählt
- Idee: Gewichtung je nach Nutzer – nicht alle Interaktionstypen sind gleich wichtig
- Finales Nutzer-Embedding:

$$h_i = \sum_{r \in \{F, M, PP, CP\}} \alpha_i^r \cdot h_i^r$$

- $\alpha_i^r$  ist die Bedeutung der Relation  $r$  für Nutzer  $i$  (per Softmax)

*Beispiel: Für einen Nutzer zählen gemeinsame Präferenzen stärker als direkte Treffen.*

# Cross-Relation Attention (Beispiel)



*Die vier relation-spezifischen Embeddings werden gewichtet kombiniert.*

- Bestimmt, welche Nachbarn für die Vorhersage wichtig sind
- Berücksichtigt sowohl direkte als auch indirekte Beziehungen
- Ermöglicht eine dynamische Anpassung der Gewichtung  $a_{ij}$  zwischen Nutzer  $i$  und Nutzer  $j$

$$a_{ij} = \frac{\exp(\text{LeakyReLU}(W[h_i|h_j]))}{\sum_{k \in N(i)} \exp(\text{LeakyReLU}(W[h_i|h_k]))}$$

mit


LeakyReLU = Aktivierungsfunktion

$h_i, h_j$  = Embeddings von zwei Nutzern

$W$  = Lernbare Gewichtsmatrix

# Attention-Mechanismus: Beispiel

- Nicht alle Nachbarn sind gleich wichtig
- Attention gewichtet Einflüsse individuell
- z.B.: Nutzer u3 ist für u1 besonders relevant



- Drei reale LBSN-Datensätze: Gowalla, Brightkite, Foursquare
- Nutzung aller Daten – realistische Szenarien

|                       | <b>Gowalla</b> | <b>Brightkite</b> | <b>Foursquare</b> |
|-----------------------|----------------|-------------------|-------------------|
| <b>Check-ins</b>      | 6.4 Millionen  | 4.5 Millionen     | 33.2 Millionen    |
| <b>Nutzer</b>         | 197 000        | 58 000            | 267 000           |
| <b>Freundschaften</b> | 950 000        | 214 000           | -                 |
| <b>Quelle</b>         | [1]            | [1]               | [5, 4]            |


- MRGAN schlägt alle bekannten Modelle (u.a. SRINet, HMGCL)
- Metriken: ROCAUC, PRAUC
- Durchschnittliche Verbesserung:  $\approx 5\%$

# Ergebnisse: Vergleich aller Modelle

| Modell             | Gowalla       |               | Brightkite    |               | Foursquare    |               |
|--------------------|---------------|---------------|---------------|---------------|---------------|---------------|
|                    | ROCAUC        | PRAUC         | ROCAUC        | PRAUC         | ROCAUC        | PRAUC         |
| DeepWalk           | 0.6035        | 0.6172        | 0.5963        | 0.6130        | 0.6137        | 0.6039        |
| node2vec           | 0.612         | 0.6159        | 0.6133        | 0.6014        | 0.6257        | 0.6211        |
| GCN                | 0.6275        | 0.6318        | 0.6167        | 0.6312        | 0.6276        | 0.6153        |
| R-GCN              | 0.6928        | 0.7013        | 0.6842        | 0.6913        | 0.6795        | 0.6923        |
| HAN                | 0.7685        | 0.7863        | 0.7512        | 0.7683        | 0.7530        | 0.7616        |
| HGMAE              | 0.8265        | 0.8364        | 0.8106        | 0.8203        | 0.8051        | 0.8103        |
| emb-cat            | 0.6405        | 0.6337        | 0.6515        | 0.6426        | 0.6359        | 0.6496        |
| Heter-GCN          | 0.7753        | 0.7867        | 0.7596        | 0.7481        | 0.7562        | 0.7633        |
| MVMN               | 0.7612        | 0.7831        | 0.7456        | 0.7434        | 0.7573        | 0.7648        |
| LBSN2Vec++         | 0.7521        | 0.7472        | 0.7286        | 0.7188        | 0.7352        | 0.7269        |
| MSC-LBSN           | 0.7892        | 0.8054        | 0.7705        | 0.7628        | 0.7736        | 0.7721        |
| HHGNN              | 0.7963        | 0.8016        | 0.7986        | 0.8103        | 0.7857        | 0.7969        |
| HMGCL              | <u>0.8356</u> | 0.8409        | 0.8163        | 0.8279        | <u>0.8301</u> | 0.8329        |
| SRINet             | 0.8315        | <u>0.8693</u> | <u>0.8166</u> | <u>0.8362</u> | 0.8290        | <u>0.8336</u> |
| <b>MRGAN</b>       | <b>0.8901</b> | <b>0.9010</b> | <b>0.8693</b> | <b>0.8772</b> | <b>0.8543</b> | <b>0.8695</b> |
| <i>Improvement</i> | 6.52 %        | 3.64 %        | 7.11 %        | 4.90 %        | 2.91 %        | 4.30 %        |


**Tabelle:** Leistungsvergleich aller Modelle auf drei Datensätzen. Beste Ergebnisse fett, beste Baselines unterstrichen.

# ROCAUC-Vergleich auf Gowalla (alle Modelle)




*MRGAN erzielt den höchsten ROCAUC-Wert (0,89) auf Gowalla, deutlich vor allen Baselines.*


- Entfernen einzelner Komponenten zeigt deren Relevanz
- Besonders wichtig: Meeting-Relation + Attention-Mechanismen




(a) ROCAUC w.r.t. relations



(b) PRAUC w.r.t. relations



(c) ROCAUC w.r.t. attentions



(d) PRAUC w.r.t. attentions

*Fazit: Alle vier Beziehungstypen + Attention sind nötig*

## Stärken:

- Explizite Modellierung direkter und indirekter Beziehungen
- Adaptive Gewichtung über Attention
- Sehr gute Performance

## Schwächen:

- Komplexität und Rechenaufwand
- Viele Parameter
- Fokus nur auf binäre Freundschaften

- MRGAN kombiniert Mobilitätsdaten und Beziehungswissen effektiv
- Nutzt Attention, um relevante Muster zu identifizieren
- Eignet sich besonders für Szenarien mit unvollständigen sozialen Daten

*MRGAN ist ein leistungsstarker Ansatz zur Freundschaftsinferenz aus Bewegungsdaten.*

Vielen Dank für Ihre Aufmerksamkeit!

Fragen oder Anmerkungen?

- [1] Eunjoon Cho, Seth A. Myers und Jure Leskovec. „Friendship and mobility: user movement in location-based social networks“. In: *Proceedings of the 17th ACM SIGKDD International Conference on Knowledge Discovery and Data Mining*. KDD '11. San Diego, California, USA: Association for Computing Machinery, 2011, S. 1082–1090. ISBN: 9781450308137. DOI: 10.1145/2020408.2020579. URL: <https://doi.org/10.1145/2020408.2020579>.
- [2] Guangming Qin u. a. „Multi-relational graph attention network for social relationship inference from human mobility data“. In: *Proceedings of the Thirty-Third International Joint Conference on Artificial Intelligence*. IJCAI '24. Jeju, Korea, 2024. ISBN: 978-1-956792-04-1. DOI: 10.24963/ijcai.2024/256. URL: <https://doi.org/10.24963/ijcai.2024/256>.

- [3] Guangming Qin u. a. *Source Code for MRGAN\_IJCAI*. 2024. URL: [https://github.com/qinguangming1999/MRGAN\\_IJCAI](https://github.com/qinguangming1999/MRGAN_IJCAI) (besucht am 17.04.2025).
- [4] Dingqi Yang, Daqing Zhang und Bingqing Qu. „Participatory cultural mapping based on collective behavior in location based social networks“. In: *ACM Transactions on Intelligent Systems and Technology* (2015). in press.
- [5] Dingqi Yang u. a. „NationTelescope: Monitoring and visualizing large-scale collective behavior in LBSNs“. In: *Journal of Network and Computer Applications* 55 (2015), S. 170–180.