

# LLM に基づく説明可能な ソーシャルネットワークの将来予測

方 俊翔<sup>†</sup> 伊藤 寛祥<sup>††</sup> 徐 哲林<sup>††</sup> 森嶋 厚行<sup>††</sup>

<sup>†</sup> 筑波大学情報学群知識情報・図書館学類 〒305-8550 茨城県つくば市春日 1-2

<sup>††</sup> 筑波大学図書館情報メディア系 〒305-8550 茨城県つくば市春日 1-2

E-mail: <sup>†</sup>{s2213022}@u.tsukuba.ac.jp, <sup>††</sup>{ito, morishima}@slis.tsukuba.ac.jp {zhelin}@ce.slis.tsukuba.ac.jp

**あらまし** ソーシャルネットワークにおける将来予測は、ネットワーク進化の理解および将来関係の推定において重要な課題である。既存研究では、ヒューリスティック指標やグラフニューラルネットワーク (GNN) に基づく手法が主に用いられてきたが、多くの場合、これらは構造情報への依存が強く、ノードが持つ意味的コンテキストの活用や、予測結果の説明可能性に課題が残されている。一方、大規模言語モデル (LLM) は高度な文脈理解と推論能力を有するものの、ソーシャルネットワークの将来予測への有効性は十分に検証されていない。本研究では、LLM がソーシャルネットワークにおける構造的な情報と意味的情報を統合し、将来予測にどの程度できるかを検討する。NIPS 共著ネットワークを用いた実験により、(i) LLM による予測精度の評価、(ii) 予測に寄与する情報要素の分析、(iii) 判断理由の生成の可能性の検討を行った。その結果、提案手法は既存手法と比較して高い精度を示すとともに、各要素が予測結果に与える影響と、予測根拠を自然言語で提示できることを確認した。

**キーワード** ソーシャルネットワーク予測, LLM, リンク予測, 説明可能性

## 1 はじめに

### 1.1 研究の背景

近年、インターネットの発展に伴い、人々のコミュニケーション形態は大きく変化している。Facebook, X (旧 Twitter), Instagram などの代表的なソーシャルネットワークサービス (SNS) は、世界中で広く利用されており、物理的距離を超えた情報共有や人間関係の構築が日常的に行われている。また、学術分野における研究者の共著関係ネットワークや、E コマースにおけるユーザと商品の購買関係など、多くの社会活動は人や対象をノード (頂点)、関係性をエッジ (辺) として表現するグラフ構造データとして捉えることができる。

これらのソーシャルネットワークは、時間の経過とともに新たなノードやエッジが生成・消滅する動的な性質を有している。また、将来のヒット予測ランキングの結果からグッズの生産やイベント企画やソーシャルメディアでのトレンド予測など実世界で予測に基づいた計画が幅広く行われている。その結果、このような動的なネットワークに対して、観測済みのデータから将来の状態を推定するソーシャルネットワークの将来予測は、ネットワーク科学およびデータマイニング分野における重要な研究課題の一つである。

ソーシャルネットワークの将来予測は、実社会において

も幅広い応用可能性を持つ。例えば、SNS における友人推薦やフォロー推薦、学術ネットワークにおける将来的な共同研究関係の予測、さらには感染症拡散モデルにおける接触関係の推定など、予測結果に基づく意思決定支援が多く分野で行われている。そのため、精度の高い将来予測手法が強く求められている。

一方で、ソーシャルネットワークにおけるリンク形成は、単純な構造的要因のみによって決定されるものではない。個人の興味関心や行動履歴、社会的役割、さらには時代的・社会的文脈といった多様な要因が複合的に影響し合うことで成立している。このような複雑な意思決定過程を適切にモデル化することは、依然として困難な課題である。本研究におけるソーシャルネットワークの将来予測とは、時間  $t$  までに観測されたネットワーク  $G(t)$  に基づき、将来時刻  $t + \Delta t$  においてノード対間にエッジが形成されるか否かを推定する問題である。以降では、このリンク予測問題を中心に、既存研究および本研究の位置付けについて述べる。

### 1.2 既存研究と課題

ソーシャルネットワークの将来予測に関しては、これまでに多くの手法が提案されてきた。初期の研究では、共通近傍数 (Common Neighbors) [1] や Jaccard 係数 [2] といったグラフ構造に基づくヒューリスティックな指標が広く用いられてきた。これらの手法は計算コストが低い一方

で、複雑な非線形関係や高次の依存関係を十分に捉えることは難しい。

従来のリンク予測では、グラフニューラルネットワーク (GNN) [3] を用いたリンク予測手法が主流となっている。Graph Convolutional Networks (GCN) [5] や Graph Attention Networks (GAT) [19] などの手法は、ネットワーク構造を低次元のベクトル表現に埋め込み、高精度な予測を実現している。さらに、Temporal Graph Networks (TGN) [8] に代表される動的グラフ学習手法も提案され、時系列情報を考慮した予測が可能となっている。

GPT-4 や LLaMA などの大規模言語モデル (LLM) の飛躍的な進化により、テキストデータに対する高度な推論能力と常識的知識の利用が可能となった。最新の研究では、LLM をグラフ学習に統合する試みが急速に進展している。例えば、TAPE [10] は LLM を用いてテキスト属性から説明可能な特徴を抽出し GNN を強化する手法を提案しており、LinkGPT [11] は LLM を直接的なリンク予測器として利用するエンドツーエンドのフレームワークを提示している。また、ReaL-TG [12] のように、強化学習を用いて LLM に時系列グラフの推論能力を獲得させる試みも登場している。

しかし、これらの既存手法にはいくつかの課題が残されている。第一に、ノードが持つテキスト情報や意味的背景を十分に活用できていない点である。多くの手法では、テキスト属性を単純な特徴量として扱っており、語義や文脈といった高次の意味情報を適切に反映することが困難である。第二に、予測結果に対する説明可能性が低い点である。GNN を含む多くの深層学習モデルはブラックボックス的性質を持ち、なぜ特定のリンクが予測されたのかを人間に理解可能な形で説明することが難しい。このことは、実社会での応用を考える上で大きな制約となる。

### 1.3 本研究の目的とアプローチ

本研究の目的は、LLM の高度な言語理解能力および推論能力に着目し、ソーシャルネットワークの将来予測において、どの程度の予測精度が達成可能であることを明らかにするとともに、その予測過程を人間が理解可能な形で説明できるかを検討することである。

本研究では、ソーシャルネットワークの将来予測を単なる構造的欠損補完問題としてではなく、ネットワーク上のノードが有する文脈情報に基づく意思決定結果として捉える。具体的には、各ノードに付随する過去の接続履歴、周辺構造、および属性・テキスト情報を将来予測における入力コンテキストとして整理し、これらの情報を LLM に与えることで、リンク形成の有無を推論させる枠組みを採用する。

本研究の第一の関心は、LLM がグラフ構造およびその時間的文脈をどの程度捉え、将来のリンク形成を予測可能であるかという点にある。さらに、構造的情報、意味的情報、および時系列情報のうち、どの要素が予測性能に大きく寄与しているのかを分析することで、LLM による予測がどのような情報に依存して行われているのかを明らかにする。

また、本研究では、LLM による予測結果に対して、「なぜそのノード対が将来つながると判断されたのか」という判断根拠を、自然言語によって説明させることを試みる。これにより、予測精度のみならず、予測理由の一貫性および人間にとっての理解可能性の観点から、LLM を用いたソーシャルネットワーク将来予測手法の有効性と限界を検討する。

### 1.4 論文の構成

本論文は関連研究 (第3章)、問題設定 (第3章)、前提知識 (第4章) 提案手法 (第5章)、実験 (第6章)、まとめ (第7章) の順に構成される。

## 2 関連研究

ソーシャルネットワークのリンク予測は、未観測または将来のリンクを推定する古典的課題である。初期のヒューリスティック手法 (共通近傍数, Jaccard 係数等 [1, 2]) は解釈性が高いものの、大域構造やノード属性の活用に限界があった。その後、DeepWalk [3] や Node2Vec [4] を代表とするネットワーク表現学習、GCN [5] 等の GNN、さらに EvolveGCN [7] や TGN [8] といった動的 GNN が提案され、時間的依存関係のモデル化により精度が向上したが、依然として構造情報への依存度が高く、非構造データの意味的活用が不十分である。近年の LLM は、Transformer アーキテクチャによる広範な世界知識と、CoT プロンプティング [9] による多段階推論能力を備え、推論エンジンとしての機能が実証されている。この LLM とグラフ学習の融合研究は大きく「Enhancer」と「Predictor」に分類される：Enhancer アプローチ (例：TAPE [10]) は LLM で抽出した特徴で GNN を強化するが説明可能性に課題があり、Predictor アプローチ (例：LinkGPT [11]) は LLM に直接予測を行わせるものの、大規模グラフでのコンテキスト制約や計算コストが問題となる。本研究では、LLM を単なる特徴抽出器や予測器ではなく、構造的・意味的情報を統合して推論する主体として位置付け、特徴抽出・文章化 (モジュール 1) と推論・説明生成 (モジュール 2) を分離した構成を提案する。これにより、LLM による情報利用の様式と推論・説明能力を検討することを目的とする。

### 3 問題設定

本章では、本研究で扱うソーシャルネットワーク将来予測問題を明確に定式化するとともに、本研究が検討する三つの研究課題（Research Questions）を示す。本研究は、LLM を用いた将来リンク予測に関して、その予測性能、情報依存性、および説明可能性を体系的に分析することを目的とする。

#### 3.1 RQ1：LLM によるソーシャルネットワーク将来予測の精度評価

本研究では、リンク予測問題を、単なるグラフ構造の欠損補完としてではなく、ノードが周囲の環境に関する多様な情報を踏まえて関係形成を行った結果として捉える。すなわち、ソーシャルネットワークにおけるリンク形成は、確率的に自動生成されるものではなく、過去の相互作用、周辺構造、およびノードに付随する意味の情報など、複数の要因が統合された判断の結果として生じると考えられる。

例えば、研究者が将来の共著相手を選択する場合、相手の研究分野やこれまでの実績といった言語的に表現可能な情報に加え、過去の交流頻度や所属コミュニティの活発さといった数値的・構造的な情報も同時に考慮される。このように、ソーシャルネットワークにおけるリンク形成は、意味の情報と構造的情報が相互に関係しながら意思決定に影響を与える過程として理解することができる。

本研究では、このようなリンク形成の背景にある情報統合の過程を、分析上の観点として「感知（Perception）」と「認知（Cognition）」という二つの側面に分けて捉える。ここでいう感知とは、ネットワーク構造やノード属性など、予測に関連する情報が与えられる状況を指し、認知とは、それらの情報に基づいて将来のリンク形成について熟慮し判断が行われる過程を指す。本研究は、これらの情報統合の視点に基づき、LLM を用いた将来リンク予測がどの程度の予測精度を達成可能であるかを検証する。

#### 3.2 RQ2：LLM による予測において重要となる情報の分析

ソーシャルネットワークに関する情報は、大きく分けて、ノード間の接続関係や次数、共通近傍数などの構造的な情報、ノード属性や投稿内容といった意味の情報、および時間的な変化を表す時系列情報に分類できる。本研究では、これらの情報を段階的に制御・削減しながら LLM に入力することで、各情報要素が予測結果に与える影響を分析する。

このような分析により、LLM が推論を行う際にどの情報に強く依存しているのか、また、従来の構造中心の手法

とは異なる情報利用の傾向が存在するかを検討する。

#### 3.3 RQ3：LLM による将来予測結果の説明可能性の検討

近年、予測精度の向上に加えて、予測結果の解釈性や説明可能性の重要性が指摘されている。特にソーシャルネットワークに関する予測は、実社会における意思決定支援に用いられる場面が多く、「なぜその予測が行われたのか」を説明できることが求められる。

本研究では、LLM に予測結果とともに判断理由の生成を行わせ、その説明が入力情報と整合的であるか、また、人間にとって理解可能な内容となっているかを定性的に分析する。これにより、LLM を用いた将来予測における説明可能性の有効性と限界を明らかにする。

#### 3.4 記号・定義

本研究で扱う時系列グラフ（Temporal Graph）および関連する概念を以下のように定義する。

- **時系列グラフ  $G$** : 時系列グラフは、タイムスタンプ付きの相互作用（エッジ）の集合として定義される。

$$G = \{(u_i, v_i, t_i) \mid u_i, v_i \in \mathcal{V}, t_i \in \mathcal{T}, 0 \leq t_1 \leq \dots \leq t_{|G|}\}$$

ここで、 $\mathcal{V}$  はノード集合、 $\mathcal{T}$  は離散的な時間ステップを表す。

- **グラフスナップショット  $G^{(t)}$** : 特定の時間ステップ  $t$  におけるグラフの状態を表す。

$$G^{(t)} = (V, E^{(t)}, X^{(t)})$$

ここで、 $E^{(t)}$  は時刻  $t$  に存在するエッジ集合、 $X^{(t)}$  は各ノードに付随する属性情報（テキストを含む）を表す。

- **動的ペルソナ  $\mathbf{P}_u^{(t)}$** : ノード  $u$  の時刻  $t$  における発展方針を動的ペルソナと定義する。これは以下の要素を含む構造体である。

$$\mathbf{P}_u^{(t)} = \{\text{EvolutionState}^{(t)}, \text{Memory}^{(t)}\}$$

ここで、 $\text{EvolutionState}^{(t)}$  は活動の拡大・縮小傾向、 $\text{Memory}^{(t)}$  は過去の接続履歴を示す。

本研究のタスクは、時刻  $t$  までに観測された履歴情報  $\{G_\tau \mid \tau \leq t\}$  に基づき、将来時刻  $t+1$  において、ノード対  $(u, v)$  間にエッジが形成される確率  $y_{uv}^{(t+1)} \in [0, 1]$  を推定することである。

## 4 前提知識

本章では、提案手法を構成する要素技術について解説する。特に、コード実装で用いられているグラフ解析手法と、LLM の推論技術について詳述する。

#### 4.1 時系列グラフにおける構造的特徴量の抽出手法

LLM はテキスト処理には長けているが、グラフのトポロジー構造を数値行列として直接理解することは苦手とする。そのため、ノードがネットワーク内での自身の立ち位置を把握するための補助として、構造的特徴量を事前に計算し、言語化して与える必要がある。

#### 4.2 スペクトル埋め込み (Spectral Embedding)

ネットワークの大域的な構造類似性を捉えるために、スペクトル埋め込みを用いる。これはグラフのラプラシアン行列の固有値分解に基づく手法である。隣接行列を  $A$ 、次数行列を  $D$  とするとき、正規化ラプラシアン行列  $L_{sym} = I - D^{-1/2}AD^{-1/2}$  を構成する。この行列の固有ベクトルを用いることで、グラフ上で構造的に近いノード同士 (例えば同じコミュニティに属するノード) は、ベクトル空間上でも近い距離に配置される。本研究では、この埋め込みベクトルのコサイン類似度を「構造的類似性 (Structural Similarity)」として LLM に提示する。

#### 4.3 PageRank と中心性

ノードの重要度や影響力を測るために、PageRank アルゴリズムを使用する。これは、多くの重要なノードからリンクされているノードは重要であるという再帰的な定義に基づく。

$$PR(u) = \frac{1-d}{N} + d \sum_{v \in \mathcal{M}(u)} \frac{PR(v)}{deg(v)} \quad (1)$$

#### 4.4 集積係数 (Clustering Coefficient)

集積係数は、あるノードの隣接ノード同士が互いに接続している度合い、すなわち「友人の友人は友人である」確率を表す指標である。本研究では、ノードが所属するコミュニティの密度を LLM に伝達するために使用する。ノード  $u$  の次数を  $k_u$ 、その隣接ノード間に実際に存在するエッジ数を  $L_u$  とするとき、集積係数  $C_u$  は次式で定義される [13]。

$$C_u = \frac{2L_u}{k_u(k_u - 1)} \quad (2)$$

$C_u$  が高い場合、そのノードは強固で閉じたコミュニティに属していることを示唆し、低い場合は異なるグループをつなぐ位置にいる可能性がある。

#### 4.5 共通近傍数 (Common Neighbors)

Common Neighbors (CN) は、2つのノード  $u$  と  $v$  が共有する隣接ノードの数である。

$$CN(u, v) = |\mathcal{N}(u) \cap \mathcal{N}(v)| \quad (3)$$

社会ネットワークにおいては、共通の友人が多いほど、その2人も友人になる可能性が高いという「三者閉鎖 (Triadic

Closure)」の原理が働くため、この指標はリンク予測において強力な特徴量となる。

#### 4.6 ジャカード係数 (Jaccard Coefficient)

共通近傍数を、両ノードの次数 (友人数) の和集合で正規化したものである。

$$Jaccard(u, v) = \frac{|\mathcal{N}(u) \cap \mathcal{N}(v)|}{|\mathcal{N}(u) \cup \mathcal{N}(v)|} \quad (4)$$

次数が非常に高いハブノード (有名人など) とのリンク確率が過大評価されるのを防ぐ効果がある。

#### 4.7 重み付き・時間的指標

時系列グラフにおいては、単なる接続の有無だけでなく、「いつ」「何度」接続したかが重要となる。本研究では、最近の相互作用を重視するために、時間減衰 (Time Decay) を考慮した重み付き指標を用いる。これにより、ノードにとって「最近よく交流しているコミュニティ」を適切に反映させることができる。

#### 4.8 ベクトル類似度尺度

本研究では、スペクトル埋め込みによって得られた構造ベクトルや、キーワード集合から生成された特徴ベクトルの類似性を評価するために、コサイン類似度 (Cosine Similarity) を用いる。二つのベクトル  $\mathbf{a}, \mathbf{b}$  のなす角を  $\theta$  とするとき、コサイン類似度は以下のように定義される。

$$Sim_{cos}(\mathbf{a}, \mathbf{b}) = \cos(\theta) = \frac{\mathbf{a} \cdot \mathbf{b}}{\|\mathbf{a}\| \|\mathbf{b}\|} = \frac{\sum_{i=1}^n a_i b_i}{\sqrt{\sum_{i=1}^n a_i^2} \sqrt{\sum_{i=1}^n b_i^2}} \quad (5)$$

## 5 提案手法

本章では、ソーシャルネットワークにおけるリンク予測を、LLM による多層的な感知 (Perception) と適応的な熟慮 (Cognition) の統合過程として定式化する。提案手法である **Neuro-Symbolic Process** は、時間的ネットワーク履歴とノード属性 (テキスト) を入力として受け取り、対象ノード対  $(u, v)$  に対する将来リンクの成立確率と、その判断根拠となる自然言語説明を同時に生成する枠組みである。本章では、提案手法の全体像 (図 1) と、モジュール 1 / モジュール 2 によって実装される各モジュールの役割・入出力・設計意図を順に述べる。

#### 5.1 システムアーキテクチャ

図 1 本研究で提案する NSP の全体フレームワークを示す。本システムは、以下の二つの処理系を明確に分離・統合したハイブリッドアーキテクチャを採用している。具体的には、(i) 大規模ネットワークから解釈可能な構造・意味シグナルを抽出する **Module 1 (Perception)** と、(ii) それらのシグナルと過去事例を根拠として熟慮的推論を行

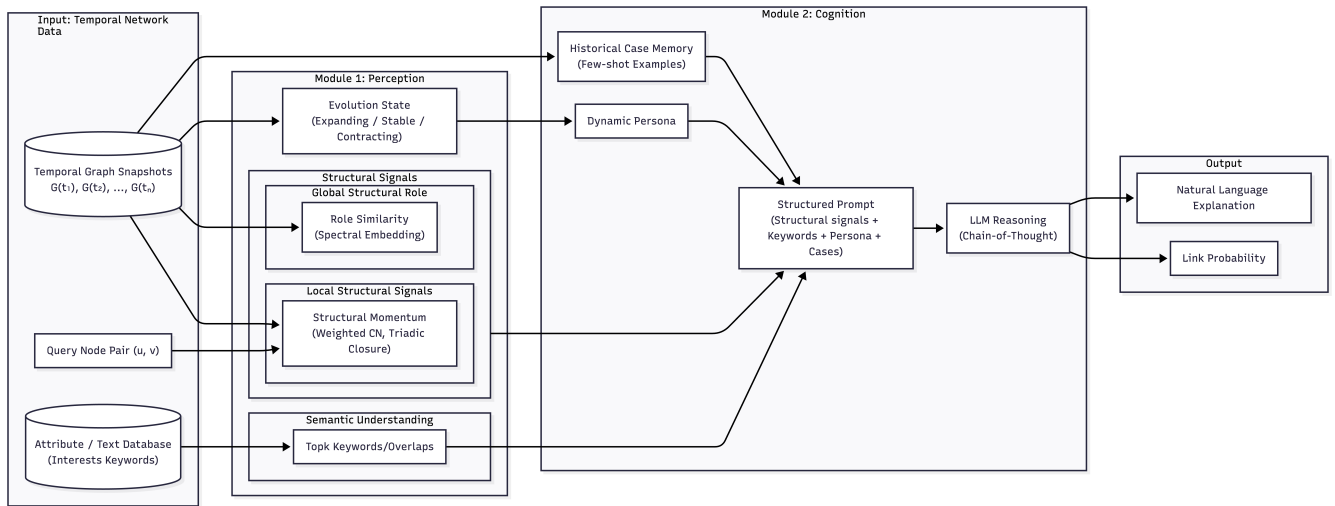


図 1: (NSP)Neuro-Symbolic Process. Input 層 (GraphDB, TextDB, QueryPair) を参照し、モジュール 1 が構造・意味・状態シグナルを抽出、モジュール 2 が動的ペルソナ・過去事例・CoT 推論を統合してリンク確率と説明を生成する。

う **Module 2 (Cognition)** によって構成される。

### 5.1.1 Input 層: Temporal Graph Database と Attribute Database

図 1 の Input 層は時間ステップ  $t_1, \dots, t_n$  におけるグラフスナップショット  $G(t)$  を蓄積した **Temporal Graph Snapshots** と、各ノードの関心・研究キーワード等の属性を格納した **Attribute / Text Database** を用意する。推論時には対象ノード対  $(u, v)$  を与え、Graph Snapshots / Text Database から必要な情報を取得して Module 1 / 2 に供給する。

### 5.1.2 モジュール 1/2: LLM を用いたパイプライン

- Module 1 (Perception / Signal Processing) :** LLM の「知覚」に相当する。GraphDB / TextDB から取得した情報に対し、(i) 構造シグナル (大域役割・局所動態), (ii) 意味シグナル (Top- $k$  キーワード重複等), (iii) ネットワーク進化状態 (拡大/安定/縮小) を計算し、LLM が解釈可能な形に整理する。すなわち情報のプリプロセッサである。
- Module 2 (Cognition / Symbolic Reasoning) :** LLM の「熟慮」に相当する。Module 1 のシグナルを根拠として動的ペルソナ (行動戦略) を形成し、過去の類似事例 (Memory) を参照しつつ、Chain-of-Thought に沿ってリンク形成を判断する。さらに、確率出力に加えて自然言語の説明を生成する。

この構成により、ネットワーク科学の厳密性 (構造指標) と LLM の柔軟な統合推論能力 (説明生成・意味統合) を両立する。

### 5.2 感知モジュール (Perception)

Module 1 は、生のグラフデータおよびテキスト属性を入力とし、図 1 に示すように、(a) 構造シグナル、(b) 意味シグナル、(c) 進化状態の 3 観点から特徴抽出を行う。ここで重要なのは、Module 1 の出力はブラックボックスな埋め込み表現ではなく、**LLM が言語化・比較・統合できる「解釈可能な証拠 (evidence)」**として構成される点である。

### 5.3 認知モジュール (Cognition)

Module 2 では、Module 1 が抽出した構造シグナル (GlobalSig/LocalSig)、意味シグナル (SemanticSig)、進化状態 (StateSig) を統合し、対象ノード対に対するプロンプトでプロフィールを構築する。

具体的には、Evolution State Detector の出力に基づき、探索 (Exploration) と活用 (Exploitation) のペルソナ方針を調整する。さらに、意味シグナル (キーワード) を用いて、対象ノードの関心をプロフィールに反映し、推論時に「どのような相手をパートナーとみなすか」という判断基準を明確化する。

Module 2 の中核をなすのが、LLM による推論プロセスである。図 1 に示すように、本手法は Module 1 の各シグナル、動的ペルソナ、さらに過去の類似事例メモリ (Memory) を **Structured Prompt** として統合し、LLM に入力する。

Structured Prompt (図 1 の Prompt) は、(i) Structural Signals (Global/Local), (ii) SemanticSig, (iii) Persona, (iv) Memory を一つの推論コンテキストに整理して含む。これにより、LLM は「どの証拠に基づき、どの順序で判断するか」を段階的に実行できる。

### 1. Step 1: Temporal Structure Analysis (時間的構造解析)

ここでは Module 1 が算出した重み付き共通近傍数 (Weighted CN) や、トライアド閉鎖の発生イベント数を確認する。

### 2. Step 2: Global Structural Role (大域的役割の評価)

次に、直接的な繋がりがなくても、ネットワーク内での役割が似ているかを確認する。

### 3. Step 3: Research Fit (研究関心の適合性)

ここではキーワードの関係性を確認する。

### 4. Step 4: Learn from History (過去の事例参照)

Memory モジュールから検索された、類似した過去の成功/失敗事例を参照する。

### 5. Step 5: Synthesis (総合判断)

最後に、すべての要素を統合して最終決定を下す。

最後、本手法では、将来リンクの成立確率を推定するだけでなく、その判断根拠を人間に理解可能で説得的な自然言語として提示することを目的とする。そのため、推論結果として確率値と併せて簡潔な理由文を生成する設計とした。

この段階的な推論を経ることで、数値モデルでは検出できない微妙なニュアンスや学際的交差を汲み取り、かつ人間にとって納得感のある「説明」を生成することが可能となる。

## 6 実験

### 6.1 データセット (NIPS 共著ネットワーク)

提案手法の有効性を検証するために、機械学習分野のトップカンファレンスである NIPS (Neural Information Processing Systems) の共著ネットワークデータセットを用いた。このデータセットは、著者 (ノード) と共著関係 (エッジ) から構成され、各著者はその年に発表した論文のタイトルに含まれる単語を属性として持ち、ノード数は 32、特徴数は 2411 である。データは 2008 年から 2017 年までの 10 年分を含んでおり、これを 1 年ごとのスナップショットに分割して時系列データとした。前半を学習用、後半をテスト用として使用した。

なお、評価フェーズにおいては、LLM の推論に伴う膨大な計算コスト (時間およびトークン消費量) を現実的な範囲に抑制するため、テストデータに対してサンプリングを適用した。

### 6.2 実験設定

提案手法における推論エンジンとして **Llama3:70B** を採用した。なお、モデルの実行環境には **Ollama** フレームワークを使用し、ローカル環境にて推論を行っている。

比較対象として、リンク予測において代表的な以下の手法を採用した。

- **Heuristic-based methods:** Jaccard 係数 [1]. いずれも局所的なネットワーク構造のみに基づく単純な指標であり、時間的情報やノード属性は考慮しない。
  - **Static Embedding methods:** Node2Vec [4]. 静的なグラフ構造からノード埋め込みを学習し、構造的類似性に基づいてリンクを予測する代表的な手法である。
  - **Temporal Sequence models:** LSTM [17]. 各ノード対の時系列特徴を入力とし、時間的依存関係をモデル化する手法である。
  - **Graph Neural Networks:** GCN [5]. グラフ構造とノード近傍情報を用いて表現学習を行うが、本実験では各スナップショットを独立に扱う静的設定で評価した。
  - **Reinforcement Learning based method:** RL [18]. リンク形成を逐次的な意思決定問題として定式化し、報酬に基づいて方策を学習する手法である。
- リンク予測では以下の指標を用いて評価を行った。
- **AUC-ROC:** 受信者操作特性曲線の下側面積。全体的なランキング性能を評価する。

### 6.3 実験結果 (時間的リンク予測性能)

図 2 に、各時間ステップ (時間ステップ 5-9) における AUC-ROC の推移を示す。

提案手法は、全ての時間ステップにわたって一貫して高い性能を示し、平均 AUC-ROC は **0.9545** に達した。

特に、ネットワーク構造が変化する時間区間においても、予測性能が大きく低下することなく安定して維持されている点が確認できる。この結果は、本手法の設計がソーシャルネットワークの将来予測において有効に機能していることを示唆している。

また、各スナップショットにおける性能のばらつきが小さいことから、本手法は単一時点に依存せず、ネットワークの進化過程全体を通じて安定した予測が可能であると考えられる。

### 6.4 アブレーション実験による各構成要素の寄与分析

提案手法における各構成要素の寄与を検証するため、主要コンポーネントを一つずつ除去したアブレーション実験

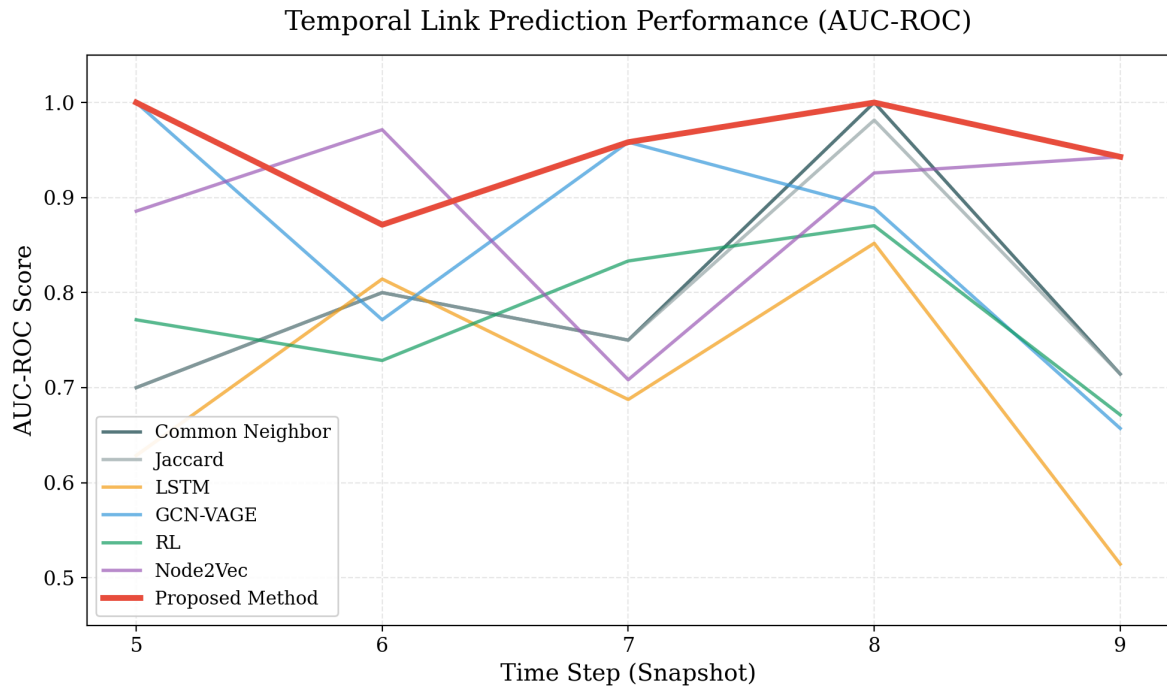


図 2: 各スナップショットにおける AUC-ROC の推移

を行った。その結果を表 1 に示す。

以上アブレーション実験の結果より、提案手法の高い性能は単一の要素によるものではなく、各シグナルを統合する設計に支えられていることが示された。

### 6.5 ケーススタディ：生成された判断理由

提案手法が生成する判断理由の具体例を示すため、リンク予測結果の一部についてケーススタディを行う。表 2 に代表的な 3 例を示す。

### 6.6 考察

本節では、第 6 章で得られた実験結果を踏まえ、提案手法 NSP が高い予測性能を示した要因、および各構成要素の役割について考察する。特に、本研究で設定した RQ1 (予測精度)、RQ2 (重要情報の分析)、RQ3 (説明可能性) の三点との対応関係に着目する。

#### 6.6.1 時間ステップを通じた安定性のある高い精度

図 2 に示したように、提案手法は時間ステップ 5-9 の全ての時間ステップにおいて高い AUC-ROC を維持し、平均で 0.9545 を達成した。時間変化に頑健な予測精度を維持できることが確認され、RQ1 「LLM による将来リンク予測の精度評価」に対する肯定的な結果を示している。

#### 6.6.2 アブレーション結果から見た主要因：局所構造動態と意味情報

アブレーション実験の結果から、LLM によるリンク予測の核心要因と補助的要素が明らかとなった。局所構造情報 (Local Structural Signals) と意味情報 (Semantic

Signal) は予測性能に決定的な影響を与え、これらを除去すると性能が大幅に低下したことから、複数の異種情報を統合した推論が有効であることが実証された (RQ2 への回答)。一方、大域的役割情報 (Global Structural Role) と動的ペルソナは補助的な役割を担う：大域的役割情報は直接的な近傍構造では説明しにくいケース (コミュニティ跨ぎの接続等) で潜在的な互換性を示し、動的ペルソナは探索 / 活用の推論方針を安定化させる機能を発揮した。また、Historical Memory は平均 AUC-ROC への直接的な貢献は限定的であったものの、類似事例に基づく説明文の説得力向上や、疎・大規模データ環境での推論の頑健性を高める価値を持つと考えられる。

#### 6.6.3 生成された判断理由の解釈性に関する考察

ケーススタディ (表 2) では、共通近傍数 (CN) や意味的重複率といった数値的証拠に基づき、予測確率と自然言語による判断理由が整合的に生成されていることが確認できる。例えば、CN や Semantic Overlap が低い場合には「moderate chance」「reasonable likelihood」といった表現が用いられ、数値的条件の弱さが言語的にも反映されている。

この結果は、LLM が与えられた構造・意味シグナルを単に読み上げるのではなく、相対的な強弱を踏まえて解釈していることを示しており、RQ3 「予測結果を説明可能か」に対して、定性的に肯定的な示唆を与えるものである。

表 1: Ablation Results across Temporal Snapshots (AUC-ROC)

Model Variant	t5	t6	t7	t8	t9	Average
Full Model	1.0000	0.8714	0.9583	1.0000	0.9429	<b>0.9545</b>
No Global Structural	1.0000	0.7857	0.9167	0.9907	0.9143	0.9215
No Local Structural	0.9286	0.8000	0.8125	0.8796	0.7857	0.8413
No Semantic Signal	0.8714	0.9143	0.9167	0.7407	0.7429	0.8372
No Dynamic Persona	1.0000	1.0000	0.7708	0.9630	0.9643	0.9396
No Historical Memory	0.9714	0.9000	1.0000	0.9259	0.9571	0.9509
Raw Graph Baseline	0.8000	0.8000	0.7500	0.6852	0.7357	0.7542

表 2: 生成された判断理由のケーススタディ

例	Reasoning (生成文)	Probability
CN = 2.55 Semantic Overlap=50%	Researcher A and B have a moderate chance of collaborating due to their shared research focus on artificial intelligence and selection, as well as their compatible network positions and stable evolution trends, indicating a sense of stability and reliability that can foster trust and cooperation.	0.75
CN = 2.75 Semantic Overlap=25%	Both researchers have stable network positions and similar research focuses, indicating a potential for mutual benefit and complementary expertise. While strong historical connections are limited, the overall context suggests a reasonable likelihood of academic collaboration.	0.65
CN = 0.61 Semantic Overlap=12%	Although they have not collaborated before, their similar research orientations and stable trends suggest a potential collaboration motivated by exploring new research directions and diversifying academic connections.	0.40

## 7 まとめ

本研究では、ソーシャルネットワークにおける将来リンク予測を、単なる構造的な欠損補完としてではなく、各ノードが環境から得られる証拠を統合して意思決定を行う**認知プロセス**として捉え直した。その上で、LLMを「予測器」ではなく「推論エンジン」として位置付け、構造・意味・状態の解釈可能なシグナルに基づく Neuro-Symbolic な推論枠組み **NSP (Neuro-Symbolic Process)** を提案した。

本手法の特徴は、処理を二つの段階 (Module 1 / Module 2) に分け、それぞれの役割を明確に整理した点にある。Module 1 では、動的ネットワーク履歴とテキスト属性から解釈可能な構造・意味・状態シグナルを抽出し、Module

2 では、それらを根拠として LLM による統合的推論を行う。

実験では、NIPS 共著ネットワークを用いた評価により、提案手法が全期間にわたり高い予測精度を維持できることを示した (RQ1)。また、アブレーション実験を通じて、局所的構造動態および意味的情報が予測において重要な役割を果たしていることを確認した (RQ2)。さらに、ケーススタディにより、予測結果と整合的な自然言語説明が生成されることを示し、LLM を用いた説明可能な将来予測の可能性を示唆した (RQ3)。

本研究の成果は、ネットワーク科学と LLM の融合領域における新たな可能性を示したが、同時にいくつかの課題も残されている。

まず、LLM の推論コストは高く、数百万ノード規模

の巨大ネットワークへの直接適用は困難である。今後は、Module 1 のフィルタリング精度を向上させ、LLM の呼び出し回数を最小化する蒸留技術などを検討する必要がある。

今後はリンク（構造）の将来予測に加え、ノード属性（興味関心・研究キーワード等）そのものも時間とともに変化するという前提に立ち、属性の変化を同時にモデル化することで、より現実的な将来予測へ拡張することが課題である。

以上を通じて、本研究は、リンク予測を高精度に行うだけでなく、その判断根拠を人間に理解可能な形で提示するという観点から、LLM を用いた将来予測の新たな活用可能性を示した。また、より大規模かつ多様なデータセットへの適用や、説明の定量評価手法の確立を通じて、実運用に耐える予測枠組みへと発展させることを目指す。

## 謝辞

本研究の一部は JSPS 科研費 (22H00508, 22K17944) と、JST CREST(Grant Number JPMJCR22M2) AIP チャレンジの支援を受けたものである。ここに謝意を示す。

## 参考文献

- [1] Liben-Nowell, D., & Kleinberg, J. (2007). The link-prediction problem for social networks. *Journal of the American society for information science and technology*, 58(7), 1019–1031.
- [2] Adamic, L. A., & Adar, E. (2003). Friends and neighbors on the web. *Social networks*, 25(3), 211–230.
- [3] Perozzi, B., Al-Rfou, R., & Skiena, S. (2014). DeepWalk: Online learning of social representations. *Proceedings of the 20th ACM SIGKDD international conference on Knowledge discovery and data mining*, 701–710.
- [4] Grover, A., & Leskovec, J. (2016). node2vec: Scalable feature learning for networks. *Proceedings of the 22nd ACM SIGKDD international conference on Knowledge discovery and data mining*, 855–864.
- [5] Kipf, T. N., & Welling, M. (2017). Semi-supervised classification with graph convolutional networks. *International Conference on Learning Representations (ICLR)*.
- [6] Hamilton, W., Ying, Z., & Leskovec, J. (2017). Inductive representation learning on large graphs. *Advances in neural information processing systems*, 30.
- [7] Pareja, A., Domeniconi, G., Chen, J., Ma, T., Suzumura, T., Kanezashi, H., ... & Kaler, T. (2020). EvolveGCN: Evolving graph convolutional networks for dynamic graphs. *Proceedings of the AAAI Conference on Artificial Intelligence*, 34(04), 5363–5370.
- [8] Rossi, E., Chamberlain, B., Frasca, F., Eynard, D., Monti, F., & Bronstein, M. (2020). Temporal Graph Networks for Deep Learning on Dynamic Graphs. *arXiv preprint arXiv:2006.10637*.
- [9] Wei, J., Wang, X., Schuurmans, D., Bosma, M., Xia, F., Chi, E., ... & Zhou, D. (2022). Chain-of-thought prompting elicits reasoning in large language models. *Advances in Neural Information Processing Systems*, 35, 24824–24837.
- [10] He, X., Bresson, X., Laurent, T., & Hooi, B. (2023). Harnessing Explanations: LLM-to-LM Interpreter for Enhanced Text-Attributed Graph Representation Learning. *International Conference on Learning Representations (ICLR)*.
- [11] He, Z., Liu, Z., & Zhao, P. (2024). LinkGPT: Teaching Large Language Models To Predict Missing Links. *arXiv preprint arXiv:2406.04640*.
- [12] Ding, Z., Huang, S., Cao, Z., Kondrup, E., Yang, Z., Huang, X., Sui, Y., Yuan, Z., Zhu, Y., Hu, X., He, Y., Poursafaei, F., Bronstein, M., & Vlachos, A. (2025). Self-Exploring Language Models for Explainable Link Forecasting on Temporal Graphs via Reinforcement Learning. *arXiv preprint arXiv:2509.00975*.
- [13] Watts, D. J., & Strogatz, S. H. (1998). Collective dynamics of 'small-world' networks. *Nature*, 393(6684), 440–442.
- [14] Brown, T., Mann, B., Ryder, N., Subbiah, M., Kaplan, J. D., Dhariwal, P., ... & Amodei, D. (2020). Language models are few-shot learners. *Advances in neural information processing systems*, 33, 1877–1901.
- [15] Lu, X., et al. (2024). Improving Temporal Link Prediction via Temporal Walk Matrix with Time Decay. *Advances in Neural Information Processing Systems (NeurIPS)*.
- [16] Chen, Z., Mao, H., Li, H., Jin, W., Wen, H., Wei,

- X., ... & Tang, J. (2023). Exploring the potential of large language models (LLMs) in learning on graphs. *ACM SIGKDD Explorations Newsletter*, 25(2), 42–61.
- [17] Hochreiter, S., & Schmidhuber, J. (1997). Long short-term memory. *Neural Computation*, 9(8), 1735–1780.
- [18] Miyake, K., Ito, H., Faloutsos, C., Matsumoto, H., & Morishima, A. (2024). NETEVOLVE: Social Network Forecasting using Multi-Agent Reinforcement Learning with Interpretable Features. *Proceedings of the ACM Web Conference 2024 (WWW '24)*, 2542–2551.
- [19] Veličković, P., Cucurull, G., Casanova, A., Romero, A., Liò, P., & Bengio, Y. (2018). Graph Attention Networks. *International Conference on Learning Representations (ICLR)*.
- [20] Trivedi, R., Farajtabar, M., Biswal, P., & Zha, H. (2019). DyRep: Learning Representations over Dynamic Graphs. *International Conference on Learning Representations (ICLR)*.
- [21] Vaswani, A., Shazeer, N., Parmar, N., Uszkoreit, J., Jones, L., Gomez, A. N., ... & Polosukhin, I. (2017). Attention is all you need. *Advances in neural information processing systems*, 30.
- [22] Park, J. S., O'Brien, J. C., Cai, C. J., Morris, M. R., Liang, P., & Bernstein, M. S. (2023). Generative agents: Interactive simulacra of human behavior. *Proceedings of the 36th Annual ACM Symposium on User Interface Software and Technology*, 1–22.
- [23] Fatemi, B., Halcrow, J., & Perozzi, B. (2023). Talk like a graph: Encoding graphs for large language models. *arXiv preprint arXiv:2310.04560*.
- [24] Page, L., Brin, S., Motwani, R., & Winograd, T. (1999). The PageRank citation ranking: Bringing order to the web. *Stanford InfoLab*.
- [25] Belkin, M., & Niyogi, P. (2003). Laplacian eigenmaps for dimensionality reduction and data representation. *Neural computation*, 15(6), 1373–1396.
- [26] Salton, G., & Buckley, C. (1988). Term-weighting approaches in automatic text retrieval. *Information processing & management*, 24(5), 513–523.
- [27] Evans, J. St. B. T., & Stanovich, K. E. (2013). Dual-Process Theories of Higher Cognition: Advancing the Debate. *Perspectives on Psychological Science*, 8(3), 223–241.