JSAI 2026 ・ 2026年度 人工知能学会全国大会

知識グラフ ／ 機械学習 ／ 計算論的認知

動的知識グラフの探索・統合を制御する統一ゲージの提案

— Gauge what Knowledge Graph needs. —

A Unified Gauge for Controlling Exploration and Integration in Dynamic Knowledge Graphs

宮内 和義 Kazuyoshi Miyauchi　独立研究者 ／ Independent Researcher　miyauchikazuyoshi@gmail.com

論文 PDF　Landing　GitHub

THE “WHEN” PROBLEM

動的知識グラフが検索すべき**「何を（What）」**は GraphRAG・Self-RAG が最適化してきた。だが新情報を**「いつ（When）」**構造として統合し、いつ探索を続けるか——その原理的な基準は無かった。

geDIG は**自由エネルギー原理（FEP）**と**最小記述長（MDL）**を操作的に橋渡しし、このトレードオフを単一スカラー F で評価する。

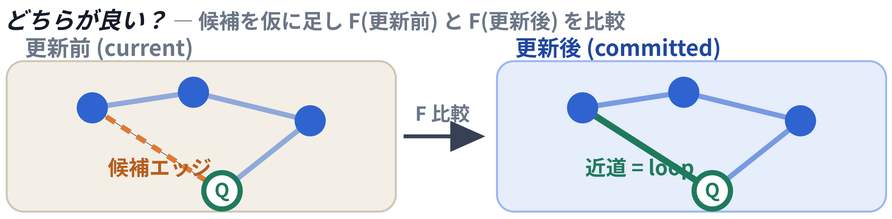

「いつ統合するか」＝候補エッジを仮に足し F(更新前) と F(更新後) を比較。**ループ短絡で近道**を生む（ΔF<0）場合のみコミット、希薄なら棄却。

GEDIG | GRAPH EDIT DISTANCE AND INFORMATION GAIN

$$F = \Delta EPC_{norm} - \lambda\,(\Delta H_{norm} + \gamma \cdot \Delta SP_{rel})$$

λ, γ = 情報温度（構造の複雑さと圧縮率のバランス）

ΔEPC_{norm} 構造変更コスト
GED の局所近似。構造を変えるほど大きい。
FEP 複雑さ ・ MDL L(M)増 ・ **抑制**

ΔH_{norm} 伸展利得 (optionality)
候補分布のエントロピー差。探索圧＝温度項。
FEP 探索圧 ・ 温度項 ・ **拡散**

ΔSP_{rel} 経路短縮 (近道)
平均最短路長の相対短縮。効率化を測る。
MDL L(D|M)圧縮 ・ **効率**

核心仮説 — 構造コストと伸展利得のトレードオフを単一スカラーで評価すれば、知識グラフの種類によらず探索と統合を統一的に制御できる。

01 CONTROL

AG／DG 二段ゲート制御

エージェントは F を用いて 2 つのゲートを**事象駆動的**に開閉し、探索モードと統合モードを自律的に切り替える。

AG Attention Gate ｜ 0-hop

$g_0 = F|_{local} > \theta_{AG}$

局所的な**「違和感・未知」**を検知 → **探索モード**を起動。

DG Decision Gate ｜ multi-hop

$g_{min} = min_h F^{(h)} < \theta_{DG}$

大域的な**「近道・洞察」**を発見 → **統合モード**でエッジを確定。

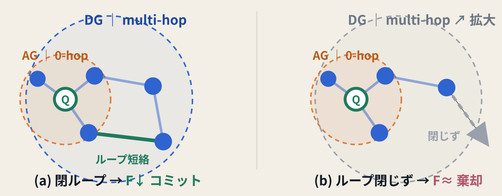

図1. **AG** は Q と**直接つながる 0-hop 近傍**（1次接続）で違和感を検知、**DG** は **multi-hop** 範囲で候補が**ループを短絡＝近道**になるかを判定。なる場合のみコミットする。

「わからないときだけ調べ（AG）、わかったときだけ覚える（DG）」

THERMODYNAMIC INTERPRETATION

熱力学的自由エネルギーとの同型性

geDIG　$F = \Delta EPC - \lambda(\Delta H + \gamma \Delta SP)$
展開　$= (\Delta EPC - \lambda\gamma\Delta SP) - \lambda\Delta H$
同型　$\cong E - T \cdot S$

構造項 ($\Delta EPC - \lambda\gamma\Delta SP$) ↔ エネルギー E、$\lambda\Delta H$ ↔ 温度×エントロピー T·S（T = λ：情報温度）。層別 F 推移は**「高温→低温への冷却＝アニーリング過程」**と読める。

高温・高エントロピー ｜ 探索　　低温・低エントロピー ｜ 構造

02 VALIDATION I ｜ SPATIAL KG

検証 I：迷路探索

部分観測迷路でエージェントが築く**認知地図**は動的知識グラフの一形態。周囲1マスしか見えず、「全通路を記憶」か「分岐点のみ記憶」かの選択を迫られる。

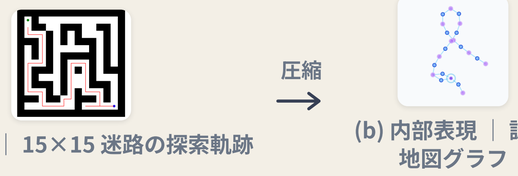

図2. 直線通路は圧縮され、**分岐点（意思決定点）**と経路のみが保持される。AG が「驚き＝未知」をノードに、DG が「理解＝因果」をエッジに記録する。

移動エピソードベクトル 8D

位置・相対移動・通行可否・訪問回数・success/goal を符号化（weights: **wall 6 / visit 4**）。クエリとの重み付き距離で候補分布を生成する。**ゴール座標・正解経路は与えない**——移動履歴のみから記憶接続を選ぶ。

98%
15×15 迷路の成功率
（Greedy DFS と同等）

98%
候補エッジの棄却率
＝記憶圧縮率

表2 ｜ 迷路ナビゲーション結果（部分観測）

手法	成功率	平均ステップ	圧縮率
15×15 （n=100, max=250）			
Random Walk	0.75 ±.08	105.8	—
Greedy DFS	0.99 ±.03	82.1	—
geDIG	**0.98** ±.03	**89.6**	**98%**
25×25 （n=60, max=500）			
Random Walk	0.40 ±.12	242.2	—
Greedy DFS	0.95 ±.06	242.2	—
geDIG	**0.75** ±.11	**254.1**	**99%**

geDIG は**「必要なトポロジー骨格」のみ**を選択的に記憶する。vs Random Walk は McNemar 検定で有意（15×15: $p<10^{-5}$）。

03 VALIDATION II ｜ SEMANTIC KG

検証 II：Transformer

Attention 行列 A_{ij} を関係グラフと見なすと**意味的 KG** が得られる（BERT 12層・SST-2・n=200）。同じ F の3項を Attention 上で定義：

グラフ化 ｜ ノード = **トークン**、エッジ = **Attention A_{ij}**（上位 10%を保持）

- ΔEPC　Attention 構成の変化＝編集コスト
- ΔH　Attention 分布の拡散＝エントロピー
- ΔSP　Attention 上の最短路の短縮

図4 ｜ BERT 12層における geDIG F 値の分布（BERT-base, SST-2, n=200）

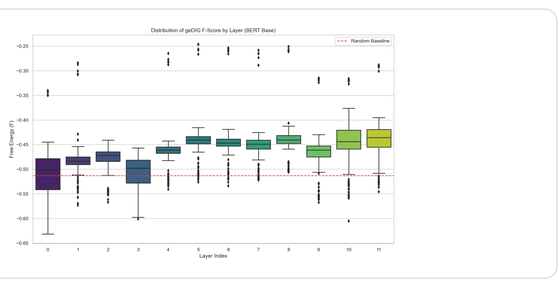

- **浅層 0–1**｜探索相（$F \approx -0.50$）
- **中層 4–5**｜構造化が進行（$F \approx -0.45$）
- **深層 10–11**｜構造相へ相転移（$F \approx -0.44$）

Layer 0–1 vs 10–11 は有意（paired $t(199)=32.6$, $p<10^{-80}$, Cohen's $d=2.31$）。ヘッドは「探索担当／統合担当」に機能分化。

表3 ｜ F 正則化の因果的介入（$L = L_{CE} + \alpha \cdot F$）

α	Accuracy (%)	Δ (pp)
0（基準）	86.00 ±.53	—
0.001	**86.33** ±.46	**+0.33***
0.01	86.27 ±.70	+0.27
0.1	85.93 ±1.1	−0.07
1.0	78.93 ±1.6	−7.07

*paired t-test p=**0.038**。**逆U字**＝微弱な正則化は改善、過剰は悪化。適切な「構造化圧」が汎化を引き出す因果的証拠。学習済み Transformer は既に F 最小化に近い。

結論と展望

- **2種の動的 KG（迷路・Transformer）**で、F が共通の構造化原理として機能することを実証。
- いずれも**探索相 → 構造相への相転移**を示し、F 正則化により F と性能の因果関係を確認。

FUTURE WORK

① ΔSP → β_1 への位相拡張。近道（ΔSP）を**第一ベッチ数 β_1**に一般化し、ループ・短絡を位相不変量として扱う。

② GraphRAG / Self-RAG への応用。AG/DG ゲートで現行 RAG の**「いつ検索し、いつ構造化するか」**を原理的に自律制御する。

主要参考：Friston 2010 (FEP) ・ Grünwald 2007 (MDL) ・ O'Keefe & Nadel 1978 (Cognitive Map) ・ Devlin 2019 (BERT) ・ Edge 2024 (GraphRAG) ・ Asai 2023 (Self-RAG)

geDIG