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
— *Gauge what Knowledge Graph needs.* —

宮内 和義 [*1]
Kazuyoshi Miyauchi

[*1]独立研究者
Independent Researcher

Dynamic knowledge graphs face a fundamental "When" problem: when to accept new information as structure, and when to continue exploration. While existing approaches such as GraphRAG optimize *what* to retrieve, they lack a principled criterion for *when* to integrate. We propose **geDIG**, a unified gauge that operationally aligns the Free Energy Principle (FEP) and Minimum Description Length (MDL), quantifying this trade-off as $\mathcal{F} = \Delta\mathrm{EPC}_{\mathrm{norm}} - \lambda(\Delta H_{\mathrm{norm}} + \gamma\Delta\mathrm{SP}_{\mathrm{rel}})$. We validate geDIG on two instantiations of dynamic knowledge graphs. (1) **Spatial KG (Maze)**: An agent building a cognitive map achieves 98% success rate while rejecting 98% of candidate edges. (2) **Semantic KG (Transformer)**: Attention matrices, viewed as token-relation graphs, exhibit a consistent transition from exploration to structure across layers ($p < 10^{-80}$), and F-regularization causally improves performance (+0.33pp, $p = 0.038$). These results suggest geDIG as a general-purpose gauge for controlling when to explore and when to integrate in dynamic knowledge graphs.

1. はじめに

動的知識グラフ（Dynamic Knowledge Graph）において，新しい情報を「いつ」構造として受け入れ，「いつ」探索を続けるべきか——この **When 問題**は未解決の基本課題である．GraphRAG[10] や Self-RAG[11] は「何を（What）」検索するかを最適化したが，「いつ（When）」統合するかはヒューリスティックに依存している．本研究では，自由エネルギー原理（FEP）[1] と最小記述長（MDL）[2] を操作的に橋渡しする統一評価関数 **geDIG** (graph edit Distance and Information Gain) を提案し，この問題に原理的な解を与える．

geDIG の核心的仮説は，「**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」というものである．本稿では，この仮説を 2 種類の動的知識グラフで検証する：

- **空間的 KG（迷路）**：エージェントが構築する認知地図
- **意味的 KG（Transformer）**：Attention 行列が表現するトークン間関係グラフ

本稿の貢献は以下の 3 点である：

1. 構造コストと伸展利得のトレードオフを単一スカラー化した geDIG の定式化
2. 2 種類の KG（迷路・Transformer）における構造相転移の実証
3. F 正則化による因果的介入実験

2. geDIG：統一評価関数の定義

geDIG は，「構造を変えるコスト」と「それによって得られる情報の質」の収支を単一スカラー $\mathcal{F}$ で評価する．

$$\mathcal{F} = \Delta\mathrm{EPC}_{\mathrm{norm}} - \lambda\left(\Delta H_{\mathrm{norm}} + \gamma \cdot \Delta\mathrm{SP}_{\mathrm{rel}}\right) \tag{1}$$

連絡先: miyauchikazuyoshi@gmail.com

ここで各項は以下に対応する（表 1）．

- $\Delta\mathrm{EPC}_{\mathrm{norm}}$：正規化 EPC (Edit Path Cost)．グラフ編集距離（GED）の局所近似であり，MDL におけるモデル記述長 $L(M)$ の増分に相当する．Δ は比較対象間の差分（迷路：更新前後 G_{t-1}, G_t，Transformer：ランダムベースラインとの差）を表す．
- ΔH_{norm}：シャノンエントロピーの差分（エントロピー増分；伸展利得, Extension Gain）．候補集合に対する重み付き分布 p のエントロピー $H(p)$ の変化として定義し，本稿では $\Delta H := H_{\mathrm{after}} - H_{\mathrm{before}}$（after-before）を採用する．$\Delta H > 0$ は候補分布の均質化（optionality の増大）を表し，探索圧として $\mathcal{F}$ を下げる（温度項）．
- $\Delta\mathrm{SP}_{\mathrm{rel}}$：平均最短路長の相対短縮率．グラフ上のショートカット形成による効率化を表し，MDL におけるデータ記述長 $L(D|M)$ の圧縮に相当する．

$\Delta\mathrm{EPC}_{\mathrm{norm}}$（$\Delta\mathrm{EPC}_{\mathrm{norm}}$）の具体形再現性のため，本稿の実装で用いた局所 GED 近似を明記する．更新前後のグラフ $G_{\mathrm{before}} = (V_b, E_b)$，$G_{\mathrm{after}} = (V_a, E_a)$ に対し，編集操作はノード/エッジの挿入・削除のみとし，

$$\mathrm{GED}(G_b, G_a) := c_V \cdot \big||V_a| - |V_b|\big| + c_E \cdot \big(|E_b \setminus E_a| + |E_a \setminus E_b|\big) \tag{2}$$

で近似する．これを正規化定数 $C_{\max}$ で割り，

$$\Delta\mathrm{EPC}_{\mathrm{norm}} \equiv \Delta\mathrm{EPC}_{\mathrm{norm}} := \mathrm{GED}(G_b, G_a)/C_{\max} \tag{3}$$

とする．迷路（検証 I）では，クエリ近傍の k-hop 局所部分グラフ上で評価し，$C_{\max} = c_V + c_E \max(1, |S_{\mathrm{link}}|)$（候補台固定）を用いた．Attention（検証 II）では $|V|$ が系列長 L で固定されるため，$c_V = 0$ かつ $C_{\max} = L^2$ とすると $\Delta\mathrm{EPC}_{\mathrm{norm}}$ はエッジ密度 $|E|/L^2$ に一致する．

$\Delta\mathrm{SP}_{\mathrm{rel}}$ の計算と計算量$\Delta\mathrm{SP}_{\mathrm{rel}}$ は「近道」の寄与を測るため，平均最短路長 $L(\cdot)$ の相対短縮として

$$\Delta\mathrm{SP}_{\mathrm{rel}} := \max\left(0, \frac{L(G_{\mathrm{before}}) - L(G_{\mathrm{after}})}{L(G_{\mathrm{before}})}\right) \tag{4}$$

表 1: geDIG 構成項の理論的対応

項	意味	FEP	MDL	役割
$\Delta\mathrm{EPC}_{\mathrm{norm}}$	構造変更	複雑さ	$L(M)$ 増	抑制
ΔH	伸展利得（optionality）	探索圧	—	拡散
$\Delta\mathrm{SP}$	経路短縮	—	$L(D\|M)$ 圧縮	効率

で定義する（$L(\cdot)$ は最大連結成分上，または固定サンプルのノードペアに対する平均）．迷路の multi-hop 評価（DG）では，全点対最短路（APSP）を毎回計算せず，固定ペア（既定 400 組）に対する距離をキャッシュし，追加エッジにより改善し得る距離のみを SSSP で増分更新することで計算量を抑えた．Transformer 解析では，層ごとのトークン関係グラフに対して同様の指標を算出し，スケール依存性を避けるためランダムベースラインからの差 $\Delta\mathcal{F}$ として解釈する．

候補集合に付与された重み w_i（類似度）から確率分布 p を

$$p_i = \frac{w_i}{\sum_j w_j}, \quad H(p) = -\sum_i p_i \log p_i \tag{5}$$

で定義し，正規化は $K = |S_{\mathrm{after}}|$ として $\Delta H_{\mathrm{norm}} = (H_{\mathrm{after}} - H_{\mathrm{before}})/\log K$ とする．

なお，$\mathcal{F}$ の絶対値は正規化・グラフ化手続きに依存するため，異なるタスク間で直接比較しない．迷路では $\mathcal{F}$ を最小化すべき目的関数（低いほど良い）として扱う一方，Transformer 解析では同条件のランダム行列（Null 仮説）からの差 $\Delta\mathcal{F} := \mathcal{F} - \mathcal{F}_{\mathrm{random}}$ を主要な解釈対象とし，$\mathcal{F}$ がランダムベースラインより 0 に近い（高い）ほど「ランダムからの構造化」が進んでいると読む．

パラメータ λ, γ は「情報温度」として機能し，構造の複雑さと情報の圧縮率のバランスを決定する．

注記：表 1 の FEP/MDL 対応は，本稿で扱うグラフ操作に対して「同型のトレードオフ構造」を与える操作的対応であり，厳密な上界・下界を与える形式的導出は今後の課題である．

2.1 AG/DG 二段ゲート制御

この $\mathcal{F}$ を用いて，エージェントは以下の 2 つのゲートを事象駆動的（Event-Driven）に制御する．

1. **AG (Attention Gate)**: 0-hop（直近）での評価．$g_0 = \mathcal{F}|_{\mathrm{local}} > \theta_{\mathrm{AG}}$ のとき，局所的な「違和感・未知」を検知し，探索モード（Exploration）を起動する．

2. **DG (Decision Gate)**: Multi-hop（数理推論）での評価．$g_{\min} = \min_h \mathcal{F}^{(h)} < \theta_{\mathrm{DG}}$ のとき，大域的な「近道・洞察」を発見したとみなし，統合モード（Integration）としてエッジを確定する．

ここで h は DG におけるルックアヘッド深さ（hop）であり，実装では候補エッジを貪欲に追加しながら $h = 0, 1, \ldots, H$（最大 $H =$ `max_hops`）の各段階で $g(h)$ を計測し，その最小値を $g_{\min}$ として用いる．

この機構により，システムは常に探索し続けるのではなく，「わからないときだけ調べ（AG）」，「わかったときだけ覚える（DG）」という自律的な振る舞いを獲得する（図 1）．

3. 検証 I：空間的 KG としての迷路探索

KG としての定式化部分観測迷路におけるエージェントの認知地図は，動的知識グラフの一形態である．ノードは訪問した位置，エッジは移動可能な接続を表し，探索に伴いグラフが動

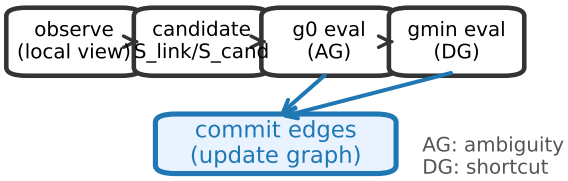

図 1: AG/DG 制御フロー．観測 → 候補生成 →AG 評価（$g_0 > \theta_{\mathrm{AG}}$ で探索継続）→DG 評価（$g_{\min} < \theta_{\mathrm{DG}}$ でコミット）の事象駆動ループ．AG は局所的異常（高 $\mathcal{F}$）を，DG は大域的効率化（低 $\mathcal{F}$）を検知する．

的に成長する．エージェントは周囲 1 マスしか見えないため，「見えた通路を全て記憶する」か「重要な分岐点のみ記憶する」かの選択を迫られる．

仮説geDIG の AG/DG ゲートにより，エージェントは (1) 高い成功率を維持しつつ，(2) 候補エッジの大半を棄却する効率的な記憶構築が可能である．すなわち，「いつ探索し，いつ構造化するか」を geDIG が自律制御できる．

実験設定15×15 および 25×25 の迷路を用いた．具体的には，各候補行動（次セル）を位置・相対移動・通行可否・訪問回数・ゴール等からなる 8 次元特徴ベクトルで表し，クエリベクトルとの距離に基づく重み付き分布から $\mathcal{F}$ を評価する．パラメータは $\lambda = 1.0, \gamma = 1.0, \theta_{\mathrm{AG}} = 0.4, \theta_{\mathrm{DG}} = 0.0$，最大ステップ数は 15×15 で 250，25×25 で 500 とした．比較対象として，(i) Random Walk（各ステップで可能行動から一様ランダムに選択し，直前の逆向きは回避），(ii) Greedy DFS（訪問済みセルを全保持し，未訪問近傍を優先するオンライン DFS），(iii) geDIG エージェントを設定した．また，記憶効率の指標として圧縮率を定義する：各ステップで生成される候補エッジ総数 $|E_{\mathrm{cand}}|$（観測近傍＋想起候補）を全て記憶する素朴方式に対し，DG でコミットしたエッジ総数 $|E_{\mathrm{commit}}|$ の棄却率 $1 - |E_{\mathrm{commit}}|/|E_{\mathrm{cand}}|$ を圧縮率とした（geDIG のみ定義）．

Algorithm 1 geDIG-driven Navigation

```
while not at goal do
    o_t ← observe(neighbors)
    g_0 ← F(G_t, o_t)        // 0-hop evaluation
    if g_0 > θ_AG then        // 違和感検知
        Expand search candidates
        for each candidate c do
            g_min ← min_h F^(h)(c)        // Multi-hop
            if g_min < θ_DG then          // 近道発見
                Update G_{t+1} with edge to c
    Move to best direction
```

図 2: geDIG による自律探索アルゴリズム．AG が探索を，DG が構造化（エッジ追加）を制御する．

3.1 結果：探索と統合の自律制御

geDIG エージェントは，AG/DG のダイナミクスのみで迷路探索に成功した（表 2）．

15×15 では，geDIG は Random Walk を成功率・効率の両面で上回り，Greedy DFS と同等の成功率を維持しながら，候補エッジの大半を棄却する高い圧縮率（98%）を達成した（図 3）．25×25 では探索空間が拡大し成功率は低下するが，それ

表 2: 迷路ナビゲーション結果（DFS 迷路，部分観測）

手法	成功率	平均ステップ	圧縮率 †
15×15 ($n = 100$, max_steps=250)			
Random Walk	0.75 ± 0.08	105.8 ± 63.9	–
Greedy DFS	0.99 ± 0.03	82.1 ± 30.8	–
geDIG	$\mathbf{0.98 \pm 0.03}$	$\mathbf{89.6 \pm 44.8}$	**98%**
25×25 ($n = 60$, max_steps=500)			
Random Walk	0.40 ± 0.12	242.2 ± 143.7	–
Greedy DFS	0.95 ± 0.06	242.2 ± 106.9	–
geDIG	$\mathbf{0.75 \pm 0.11}$	$\mathbf{254.1 \pm 125.4}$	**99%**

成功率は Wilson 95% CI の半幅（±），平均ステップは成功エピソードのみの平均 ± 標準偏差

† 圧縮率は geDIG のみ定義：各ステップで生成される候補エッジ総数 $|E_{\text{cand}}|$ を全て記憶する素朴方式と比べ，コミットしたエッジ $|E_{\text{commit}}|$ の棄却率として $1 - |E_{\text{commit}}|/|E_{\text{cand}}|$

geDIG vs Random Walk: 同一 seed での成功/失敗をペアにした McNemar 検定（15×15: $p < 10^{-5}$, 25×25: $p < 0.001$）

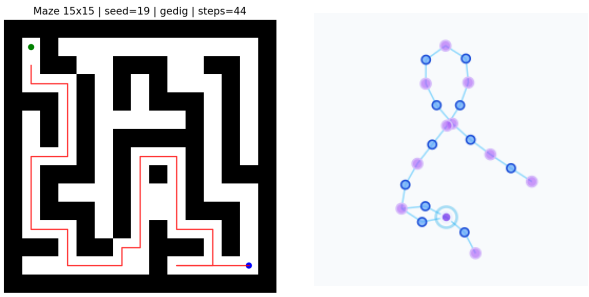

(a) 実空間の探索軌跡　(b) 抽象化された内部表現

図 3: 迷路探索における実空間と内部表現の対応．(a) 実際の迷路空間における探索軌跡．(b) geDIG が構築するエピソード記憶グラフの概念図．直線通路は圧縮され，分岐点（意思決定点，青）と経路（エッジ）のみが保持される．候補エッジに対するコミットエッジの棄却率（edge-compression）は 98% に達した．

でも Random Walk より有意に高い成功率を示した．これは，geDIG が「必要なトポロジー骨格」のみを選択的に記憶することを示す．この構築されるグラフは，O'Keefe らが提唱した認知地図 [5] や，認知科学におけるエピソード記憶の計算論的定義に対応する．本モデルでは，AG が「驚き（未知）」を検知した地点をノードとし，DG が「理解（因果）」を確定した経路をエッジとして保存する．

4. 検証 II：意味的 KG としての Transformer

KG としての定式化 Transformer の Attention 行列 A_{ij} は，トークン i からトークン j への「関係の強さ」を表す．これを閾値処理（上位 10%）してグラフ化すると，動的に変化するトークン間関係グラフ——すなわち意味的 KG——が得られる．各層でこのグラフ構造が変化することは，情報の「探索」から「統合」への遷移を表している可能性がある．

仮説学習済み Transformer は，geDIG 的な構造化を自発的に行っている．具体的には，(1) 浅層では高エントロピーな探索状態（多様なトークン関係），(2) 深層では低エントロピーな構造状態（特定トークンへの集中）への相転移が観測されるはずである．さらに，$\mathcal{F}$ を直接最適化すれば性能が変化する（因果的証拠）．

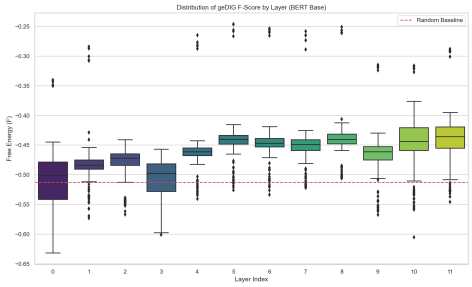

図 4: BERT における層別 F 値の推移（SST-2, $n = 200$ 文，ヘッド平均）．横軸は層番号，縦軸は F 値（生の $\mathcal{F}$）．破線はランダム行列のベースラインであり，$\mathcal{F}$ がベースラインより 0 に近い（高い）ほど「ランダムからの構造化」が進む．浅層（Layer 0-1）では F 値が低く高エントロピーな探索状態にあり，深層（Layer 10-11）では F 値が上昇し安定した構造化状態に収束する（Layer 0-1 vs 10-11: $p < 10^{-80}$）．

実験設定対象モデルは BERT[7]（12 層）である．SST-2（train）から短文 200 件を抽出し，各入力シーケンスを 1 サンプルとした．各層の $\mathcal{F}$ はヘッド平均の Attention 行列から算出した（$\lambda = 0.5, \gamma = 0.5$, 系列長は最大 128 token, 閾値は上位 10%）．なお，本解析では $\mathcal{F}$ の生値ではなく，完全ランダム（Null 仮説）からの差 $\Delta\mathcal{F}$（ベースラインからの乖離）を主要な解釈対象とする．これは閾値処理や系列長により $\mathcal{F}$ の絶対スケールが変化し得るためである．閾値は 5%〜20%の範囲で変化させても同様の傾向が確認された．

4.1 観測 1：層別の構造相転移

本稿でいう「相転移」は，臨界点や秩序変数の存在を主張するものではなく，層方向に沿った探索相 → 構造相の**レジーム変化**を便宜上そう呼ぶ．図 4 に BERT の層別 F 値分布を示す．学習済みモデルの Attention 重みは，ランダム行列（同密度）に比べて $\mathcal{F}$ が有意に高い値（0 に近い）を示した（paired $t(199) = 24.4$, $p < 10^{-60}$, $n = 200$）．

さらに重要な発見は，深さ方向の推移である：

- **Layer 0-1**: F 値が低く（≈ -0.50），エントロピーが高い「探索相」．
- **Layer 4-5**: F 値が上昇し（≈ -0.45），構造化が進む．
- **Layer 10-11**: 高い値で安定する「構造相」への相転移（≈ -0.44）．

Layer 0-1 と Layer 10-11 の差は統計的に有意である（paired $t(199) = 32.6$, $p < 10^{-80}$, Cohen's $d = 2.31$）．この結果は，Transformer が層を重ねるごとに情報を「探索」から「結晶化」へと移行させていることを示唆する．

4.2 観測 2：ヘッドの機能分化

同一層内でもヘッドごとに F 値のばらつきが見られた．一部のヘッドは極めて低い F 値（拡散的で高エントロピー）を示し，他方は高い F 値（集中した注意＝低エントロピー）を示した．これは Attention Head が「探索担当」と「統合担当」のマルチエージェントとして機能分化していることを示唆する．

4.3 観測 3：F 正則化による因果的介入

以上の観測は相関関係に過ぎない．$\mathcal{F}$ が真に性能に関与しているなら，この値を直接最適化することで性能が変化す

表 3: F 正則化の効果（SST-2, DistilBERT, $n = 3$ seeds）

α	Accuracy (%, mean ± std)	Δ (pp)
0 (Baseline)	86.00 ± 0.53	–
0.001	**86.33*** ± 0.46	+0.33
0.01	86.27 ± 0.70	+0.27
0.1	85.93 ± 1.10	-0.07
1.0	78.93 ± 1.55	-7.07

* paired t-test: $p = 0.038$ vs Baseline（seed 対応, $n = 3$）
+0.33pp は誤り率を約 2.4%相対減（14.0%→13.7%）

るはずである．DistilBERT を用いた SST-2 タスクの Fine-tuning において，損失関数に F 項による正則化を追加した：$L_{\text{total}} = L_{\text{CE}} + \alpha \cdot \mathcal{F}$.

実装詳細（再現性）モデルは `distilbert-base-uncased`, SST-2（train 1000 / validation 500），最大長 128，epoch=3, batch=16，AdamW（lr=2×10^{-5}，weight_decay=0.01）で学習した．$\mathcal{F}$ は **post-softmax の Attention 重み**から各層・各ヘッドで算出し，層平均を損失に加えた．エッジ抽出の閾値処理は非微分な top-k の代わりに，各ヘッドの 90 パーセンタイルを中心とした sigmoid による **soft-threshold**（温度 0.1）で近似し，密度（EPC）とエントロピーは微分可能に計算した．$\Delta\text{SP}_{\text{rel}}$ は soft adjacency の有限長（≤ 4）パワーに基づく到達度 proxy で近似した（閾値の勾配は安定化のため近似上固定）.

実験の結果（表 3），微弱な正則化（$\alpha = 0.001$）でベースラインから有意に改善した（paired t-test, $p = 0.038$, $n = 3$ seeds）．加えて，3/3 seeds で一貫した改善（+0.2〜0.4pp）が観測された．一方で，過剰な正則化（$\alpha \geq 0.1$）は性能を悪化させた（表 3）．この逆 U 字型の特性は，適切な「構造化圧」がモデルの汎化性能を引き出すことを因果的に示している．

注目すべきは，微弱な正則化（$\alpha = 0.001$）でも有意な改善が見られた点である．これは，学習済み Transformer が既に $\mathcal{F}$ 最小化に近い状態で動作していることを示唆する．すなわち，Transformer は学習過程で自発的に構造化圧を獲得しており，geDIG はその「隠れた最適化目標」を顕在化したものと解釈できる．

5. 関連研究

本研究の理論的基盤は，Friston の自由エネルギー原理（FEP）[1] と Grünwald の最小記述長（MDL）[2] である．両者は「複雑さと適合度のトレードオフ」という点で数学的に対応し [9]，geDIG はこの対応をグラフ編集距離 [8] で操作可能にした．また，GNN[12] は確率的埋め込みでグラフを処理するが，geDIG は構造コストと情報利得を明示的に分離・統合する点で異なる．認知地図の概念 [5] は空間的 KG としての迷路実験の理論的背景を与える．

6. 考察とおわりに

本研究では，2 種類の動的 KG——空間的 KG（迷路）と意味的 KG（Attention）——において，geDIG 評価関数 $\mathcal{F}$ が共通の「構造化原理」として機能することを示した．両者に共通するのは，高エントロピーな探索相から低エントロピーな構造相への相転移である：迷路では時間軸に沿って未知領域の拡張から経路の確定へ，Transformer では層方向に沿って Layer 0-1 の多様なヘッド活性化から Layer 10-11 の特定ヘッドへの集中へと遷移する．F 正則化実験により，この $\mathcal{F}$ とモデル性能の因果関係を実証した．

geDIG と自由エネルギーgeDIG の式 $\mathcal{F} = \Delta\text{EPC}_{\text{norm}} - \lambda(\Delta H_{\text{norm}} + \gamma \cdot \Delta\text{SP}_{\text{rel}})$ は，熱力学の自由エネルギー $F = E - TS$ と同型のトレードオフ構造を持つ：構造変更コスト $\Delta\text{EPC}_{\text{norm}}$ がエネルギー E に，伸展利得 $\lambda\Delta H$ が温度 × エントロピー TS に対応する．この対応に基づけば，Transformer の層別 $\mathcal{F}$ 推移は「高温（探索）から低温（構造化）への冷却過程」として解釈できる．実際，Attention 機構が入力情報の不確実性を減じ，意味的な近道を発見・固定化するダイナミクスは，熱力学的なアニーリング過程と整合する．

今後の展望geDIG の応用として，GraphRAG[10] や Self-RAG[11] などの構造化 RAG における「いつ検索し，いつ構造化するか」の自律制御が挙げられる．現行の RAG は検索タイミングをヒューリスティックに決定しているが，geDIG の AG/DG ゲートを導入することで，知識統合の意思決定を原理的に制御できる可能性がある．

参考文献

[1] Friston, K.: The free-energy principle: a unified brain theory?, Nat. Rev. Neurosci., 11, 127–138 (2010).

[2] Grünwald, P. D.: The Minimum Description Length Principle, MIT Press (2007).

[3] Vaswani, A., et al.: Attention Is All You Need, NeurIPS (2017).

[4] Gentner, D.: Structure-mapping: A theoretical framework for analogy, Cognitive Science, 7(2), 155–170 (1983).

[5] O'Keefe, J., Nadel, L.: The Hippocampus as a Cognitive Map, Oxford University Press (1978).

[6] Bronstein, M. M., et al.: Geometric deep learning: going beyond euclidean data, IEEE Signal Processing Magazine, 34(4), 18–42 (2017).

[7] Devlin, J., et al.: BERT: Pre-training of Deep Bidirectional Transformers for Language Understanding, NAACL (2019).

[8] Bunke, H.: On a relation between graph edit distance and maximum common subgraph, Pattern Recognition Letters, 18(8), 689–694 (1997).

[9] Tishby, N., et al.: The information bottleneck method, arXiv:physics/0004057 (2000).

[10] Edge, D., et al.: From Local to Global: A Graph RAG Approach to Query-Focused Summarization, arXiv:2404.16130 (2024).

[11] Asai, A., et al.: Self-RAG: Learning to Retrieve, Generate, and Critique through Self-Reflection, arXiv:2310.11511 (2023).

[12] Kipf, T. N., Welling, M.: Semi-Supervised Classification with Graph Convolutional Networks, ICLR (2017).