

HDT-AD: 超高次元変換による頑健かつ適応的な時系列異常検知

Robust and Adaptive Time-Series Anomaly Detection via Hyperdimensional Transform

走出 慧太

海城高等学校 生物部

背景情報

エッジ AI 時代の 3 つの課題

- 資源制約: 深層学習など大規模手法は高精度だが計算・メモリ負荷が大きく、現場（エッジ）展開が困難
- ノイズ: センサー値のスペイク/欠損など実運用で不可避なノイズに対する耐性と精度はトレードオフ
- 概念ドリフト: 正常の定義が時間でずれしていくため、バッチ再学習では追従が遅い

本研究が提供するもの

Hyperdimensional Computing (HDC)に基づく分散表現を用いて、軽量 ($O(D)$)・ノイズ頑健・オンライン適応を同時に満たす異常検知アーキテクチャを提案。

HDC とは何か

HDC (Hyperdimensional Computing) の要点 [1]

- $D \sim 10^4$ 次元の高次元ベクトル高次元ベクトルで情報を分散表現（擬似直交性を利用）
- 一部の次元破損に影響されにくく、ノイズ・欠損に本質的に頑健。

基本操作は 3 種類のみ

- Binding (\otimes): 概念のペアを生成
- Superposition (+): 概念の集合を表現
- Permutation (ρ): 順序を表現

既存理論との接続（カーネル接続）

- HDC の分布表現は Kernel Mean Embedding (KME) [2] の離散近似と解釈可能：

$$\mu_P = E_{x \sim P} [\varphi(x)] \approx \frac{1}{N} \sum_{i=1}^N h(x_i)$$

- MMD [3] により分布間距離を測定し、異常スコアへ：

$$MMD^2(P, Q) = \| \mu_P - \mu_Q \|^2$$

HDT (Hyperdimensional Transform) の位置付け [4]

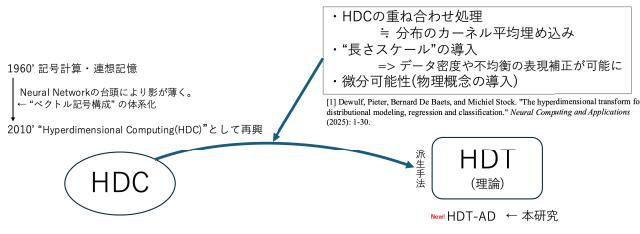
HDC の操作に厳密な数学的基礎を与える積分変換理論。

「長さスケール」を持つ特微写像 $\Delta\phi(x)$ で分布を高次元ベクトル化する。

$$\text{プロトタイプ学習: } \hat{P} = \frac{1}{m} \sum_{i=1}^m \Delta\phi(x_i) \quad (\text{加算のみで更新可})$$

なぜ今 HDC か？

- 1980-90 : HDC の理論的源流 (SDM: Kanerva, 1988 / TPR: Smolensky, 1990 / HRR: Plate, 1994) が整備。
- 2003-2004 : Gayler により Vector Symbolic Architectures (VSA) が総称として提案・整理。
- 2009-2010 : Kanerva により “Hyperdimensional Computing” として枠組みが確立・再興。
- 2015 ~ : オンデバイス学習／1 パス学習／低資源・ノイズ下での頑健性が注目され、EEG/EMG・音声・IMU の認識や異常検知への適用が拡大。産業界からも一定の関心。
- 2010 ~ 20 : 大規模データ + GPU スケールの可微分モデルが主流化し、離散演算 (XOR・多項式) は統合しづらく、評価軸が SOTA スコアに収斂したことで VSA の研究熱が相対的に低下。
- 2025 : HDT (Hyperdimensional Transform) (P. Dewulfら, 2025) の発表。時系列を高次元空間へ変換し、位相・順序・文脈を保持した VSA/HDC 互換表現で学習・推論する枠組み。



Dewulfら (2025) [1] の論文内では理論面（概念実証）とモデル内部の性質の可視化がなされた。

本研究、HDT-AD は時系列処理タスクにおける実装・性能検証を実施するものである。

図 1 HDC 研究の歴史

HDT-AD 手法概要

時系列処理への適応バイブルーン

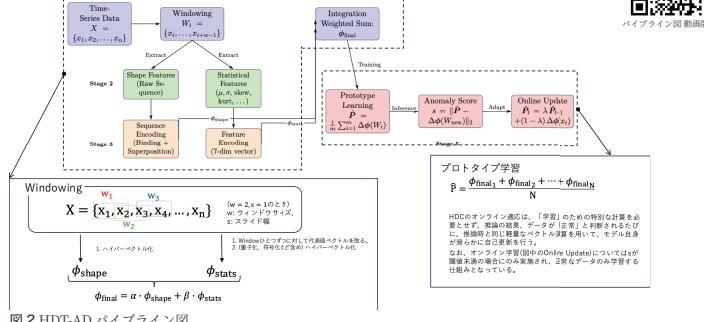


図 2 HDT-AD バイブルーン

HDT-AD を構成する 3 要素

- HDC の原理的継承: HDC が本質的に持つ分散表現によるノイズ耐性と、ベクトル加算によるオンライン適応性を最大限に活用。
- HDT による理論的深化: 最新理論 HDT を適用することで、手法全体に数学的正当性を与え、連続値の滑らかな処理と安定した適応を実現。
- 本研究独自の貢献: 時系列の形状 (Shape) と統計 (Stats) という異種情報報を、単一の超高次元ベクトルへ統合するアーキテクチャを新規に設計。

計算効率

学習・更新・推論のすべてが $O(D)$ 。メモリと演算が軽く、エッジ実装に親和的。

実験設定

データセット

- 実データ: Numenta Anomaly Benchmark (NAB) より、AWS CPU 利用率、トラフィック量など 3 種を使用。
- 合成データ: 環境変化（概念ドリフト）とセンサーノイズ（スペイク）を再現した人工データを生成。

比較手法

HDT-AD vs Isolation Forest (IF), One-Class SVM, LSTM-AE

評価軸

- 基本性能: F1-Score
- 頑健性: ノイズによる性能劣化度
- 適応性: ドリフト発生後の F1-Score

参考) ハイパー-パラメータ
IF: n_estimators=100, contamination: 0.05 (実験 3 のみ)
OC-SVM(One-Class SVM): kernel="rbf", nu=0.05
LSTM-AE: latent_dim=16, fine-tune_lr: 0.001
HDT-AD: D=10,000, λ=0.99

* HDTAD における online は逐次適応型、shape は時系列パターン特徴のみ、rich は形狀(shape) + 統計特徴(stats)の統合型。
Isolation Forest(IF)における retrain は定期的バッチ再学習、static は学習後固定、stats/shape は入力特徴の違いを示す。

実験結果

【項目 1】Feature Versatility

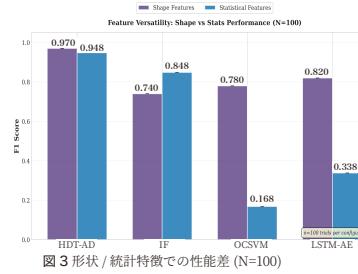


図 3 形状 / 統計特徴での性能差 (N=100)

【項目 2】Drift Adaptation

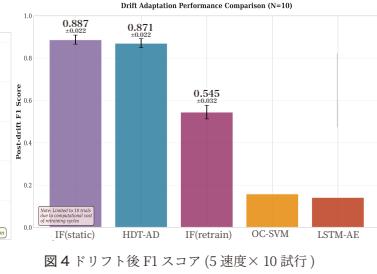


図 4 ドリフト後 F1 スコア (5 速度 × 10 試行)

【項目 3】Noise Robustness

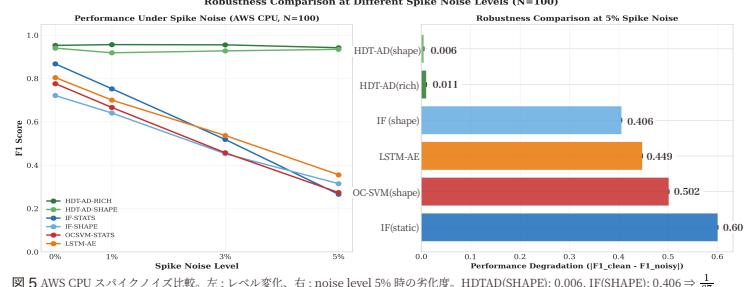


図 5 AWS CPU スパイクノイズ比較。左: レベル変化、右: noise level 5% 時の劣化度。HDTAD(SHAPE): 0.006, IF(SHAPE): 0.406 ⇒ $\frac{1}{67}$

総合性能比較

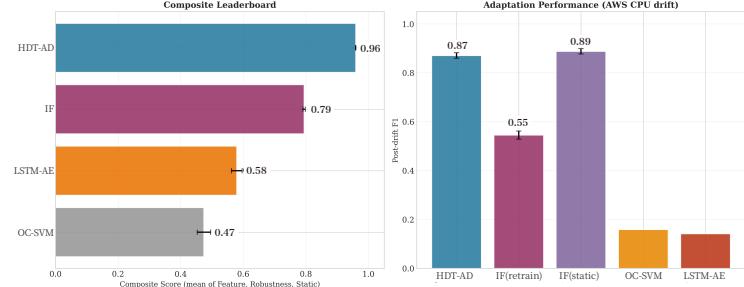


図 6 4 次元評価。左: 特徴多様性・ロバスト性・静的 F1、右: 適応性 (ドリフト後 F1)。

分析と考察

【項目 1】Feature Versatility: 多特徴適応力

HDT-AD は両特徴タイプで $0.90 \leq F1$ 達成 (差: 0.022)、競合手法は特徴依存性が高い (IF 差: 0.154、OC-SVM 差: 0.576)

「HDT の高次元空間が多様な情報源を統一的に扱える汎用アーキテクチャを実証」

⇒ 特徴量選択に依存しない予測精度

【項目 2】Drift Adaptation: ドリフト適応性

HDT-AD: 0.871, IF(retrain): 0.545 ⇒ +59.7% 向上

⇒ HDT の二角特徴により滑らかな連続適応を実現。O(I) 計算量のベクトル加算を中心操作でリアルタイム処理可能

⇒ しかしながら:

IF(static) ⇒ HDT-AD となったことについては今後の研究課題。

ドリフト適応が検出可能な範囲内であったか、IF 自体のロバスト性などの影響の可能性も考えられる。

今後の展開

機能拡張

- 多変量時系列への対応

- 自動リート検知の統合

実装・理論強化

- 軽量実装 (FPGA/Edge)

- HDT 処理・一般化誤差の理論補強

評価の拡張

- AUCPR・遲延・警報率の追加 分布距離による評価

アプレーション・検証

- D/I 組合のアプレーション online 指向ベースラインの追加 欠損・ノイズ多様化での検証

参考文献

- [1] Pentti Kanerva. Hyperdimensional Computing: An Introduction to Computing in Distributed Representation with High-Dimensional Random Vectors. Vol. 1, 2. Cognitive Computation, 2009, pp. 139–159.
- [2] Krikamol Muandet et al., "Kernel mean embedding of distributions: A review and beyond", In: Foundations and Trends in Machine Learning 10,1-2 (2017), pp. 1-141.
- [3] Arthur Gretton et al. "A kernel two-sample test". In: Journal of Machine Learning Research 13.1 (2012), pp. 723-773.
- [4] Pieter Dewulf, Bernard De Baets, and Michiel Stock. The Hyper-dimensional Transform for Distributional Modelling, Regression and Classification. arXiv:2311.08150 [cs]. Nov. 2023. DOI: 10.48550/arXiv.2311.08150. URL: http://arxiv.org/abs/2311.08150