

BAB 1

PENDAHULUAN

1.1 Latar Belakang

Masyarakat modern kini bergantung pada keandalan infrastruktur teknologi digital secara masif. Mulai dari finansial, biomedis, hingga operasional pusat data (*data center*). Dengan kompleksitas sistem yang semakin tinggi, kemunculan anomali atau penyimpangan pola yang kecil sekalipun dapat menjadi sinyal terjadinya kegagalan sistemik (*system failure*). Keterlambatan dalam mendeteksi kegagalan ini tidak hanya berdampak pada kerusakan teknis, tetapi juga menimbulkan kerugian secara finansial serta melumpuhkan operasional bisnis secara luas [1], [2]. Oleh karena itu, kemampuan untuk mendeteksi anomali sistem yang presisi dan stabil (*robust*) menjadi kebutuhan mendesak guna menjaga keberlangsungan layanan digital global.

Salah satu metode pemantauan kondisi infrastruktur digital tersebut adalah melalui sinyal-sinyal yang terekam secara urut dalam bentuk data deret waktu (*time-series*). Hampir seluruh dinamika sistem, dari mulai penggunaan CPU, *throughput* jaringan, hingga latensi disk terekam berurutan berdasarkan waktunya [3]. Sejak dulu, manusia telah lama mengukur sinyal deret waktu dari alam seperti temperatur, kecepatan angin, hingga intensitas matahari sebagai upaya memahami perilaku lingkungan. Tetapi dengan teknologi yang semakin maju, pendekatan yang sama kini diterapkan pada infrastruktur digital yang menghasilkan sinyal multivariat dari perangkat keras dan jaringan komputer menjadi fondasi utama dalam mendeteksi potensi gangguan sistem sejak dini [4].

Guna mendeteksi potensi adanya gangguan pada infrastruktur digital seperti pusat data, salah satu metode yang paling relevan adalah analisis anomali pada deret waktu atau *Time Series Anomaly Detection* (TSAD). Secara umum, analisis time series sendiri merujuk pada serangkaian tugas dengan tujuan untuk mengekstrak pengetahuan yang berarti dari suatu data yang berurut berdasarkan waktunya [4]. Sedangkan TSAD secara lebih spesifik berfokus pada deteksi titik atau pola yang menyimpang dalam deret waktu berdasarkan perilaku normalnya, yang titik maupun pola ini dapat dijadikan sinyal peringatan dini sebelum terjadi kegagalan sistem yang lebih besar.

Secara garis besar, anomali pada TSAD dapat dibagi menjadi tiga macam, yaitu anomali titik (*point anomaly*), anomali kontekstual (*contextual anomaly*), dan anomali kolektif (*collective anomaly*) [4]. Anomali poin sendiri adalah titik atau urutan yang menyimpang dari pola normal. Anomali ini biasanya berbentuk *noise temporal* dan sering disebabkan oleh kesalahan sensor atau operasi sistem yang

abnormal. Mirip dengan anomali titik, anomali kontekstual adalah data atau urutan yang menyimpang, tetapi berbeda dengan anomali titik, anomali kontekstual dikatakan sebagai anomali apabila titik atau urutan tersebut keluar atau berbeda dengan konteks yang diberikan. Sedangkan anomali kolektif mengacu pada sekumpulan titik data yang secara bertahap menunjukkan pola yang berbeda dari data normal waktu ke waktu. Anomali kolektif jika dilihat hanya dari 1 titik atau 1 *window* mungkin terlihat normal, hal inilah yang menjadi masalah karena tidak mudah dikenali sekaligus [4].

Pada penelitian kali ini, dilakukan analisis pada *dataset benchmark* TSAD *multivariate* dalam penggunaannya. Deteksi anomali pada data *time series multivariate* sendiri merupakan topik penting dalam aplikasinya di dunia nyata, seperti pada fasilitas manufaktur, wahana antariksa, bahkan pada sistem siber [5]. Dibandingkan dengan deteksi anomali deret waktu univariat, deteksi anomali multivariat lebih kompleks karena memerlukan pertimbangan hubungan dan ketergantungan temporal antara beberapa variabel secara bersamaan. Skor anomali adalah indikator yang digunakan untuk mengukur tingkat anomali suatu titik waktu atau jendela waktu. Semakin tinggi skor anomali, semakin besar kemungkinan titik data tersebut bersifat anomali [6].

Dataset yang digunakan dalam penelitian ini adalah dataset benchmark TSAD Multivariat *Server Machine Dataset* (SMD). Dataset ini merupakan kumpulan data dari 28 mesin server selama 5 minggu di sebuah perusahaan internet besar [7]. Di dalamnya SMD memuat metrik penggunaan sumber daya seperti utilisasi CPU, RAM, dan trafik jaringan yang sudah dianonimkan dan dinormalisasi dari total 28 komputer yang tersebar di 3 pusat data. Setiap mesin direpresentasikan sebagai subset tersendiri yang berisi puluhan dimensi variabel yang mencerminkan kondisi operasional server secara bersamaan. SMD ini sudah dalam bentuk metrik terstruktur dan bukan diperoleh dari proses pengambilan data secara langsung melalui log mesin server.

Maka dari itu, penelitian ini tidak mencakup tahapan *end-to-end* dari pipeline di dunia nyata seperti pengumpulan log, parsing, ataupun agregasi metrik dari infrastruktur fisik dan lebih berfokus pada tahapan deteksi anomali dari kumpulan metrik yang sudah tersedia. Karena itulah, kontribusi penelitian ini akan lebih relevan sebagai pengembangan algoritma deteksi. Sedangkan penerapannya secara penuh di dunia nyata masih memerlukan integrasi dengan sistem pengumpulan dan *pre-processing* data sebagai komponen pelengkap.

Banyak model TSAD yang sudah ada menggunakan *deep learning-based model* untuk mempelajari kebiasaan dari *positive state* dengan merekonstruksi data *time series*-nya. Tugas merekonstruksi data *time series* inilah yang memakan terlalu banyak usaha untuk merekonstruksi informasi yang tidak berguna. Tetapi baru-baru

ini, *contrastive learning* muncul sebagai teknik yang sangat kuat sebagai representasi pembelajaran tanpa adanya rekonstruksi [5]. Salah satu metode yang menonjol dalam menggunakan *contrastive learning* untuk menyelesaikan permasalahan ini adalah TiCTok (*Time-Series Anomaly Detection with Contrastive Tokenization*) yang menggabungkan tokenisasi, CNN encoder, *autoregressive Transformer*, dan *Contrastive Predictive Coding* (CPC) untuk mempelajari representasi pola normal tanpa menggunakan label anomali.

Sebagai salah satu model terkini, TiCTok telah menunjukkan kemampuannya dalam mengelola kompleksitas data time-series multivariate melalui mekanisme *Contrastive Tokenization* yang sangat efektif. Namun, seperti halnya pada arsitektur umum berbasis *Self-Supervised Learning*, terdapat tantangan mendasar dalam menjaga kaya akan informasi di ruang laten, yaitu risiko terjadinya kegagalan representasional, di mana model cenderung memetakan fitur yang berbeda ke dalam representasi yang terlalu seragam [5]. Tantangan ini sangat penting ketika model diaplikasikan pada dataset industri yang kompleks, karena kurangnya variasi dalam data dapat mengganggu kemampuan model untuk membedakan antara pola normal dan anomali, terutama yang sulit dideteksi.

Beberapa penelitian terbaru menyarankan penggunaan mekanisme transformasi *embedding multi-view* sebagai salah satu cara untuk menciptakan representasi yang lebih beragam dalam pembelajaran *self-supervised*. Pendekatan ini memungkinkan model mempelajari informasi dari berbagai sudut pandang proyeksi yang berbeda, sehingga berpotensi mempengaruhi sifat representasi laten yang dihasilkan [8]. Oleh karena itu, penelitian ini mengusulkan menggabungkan arsitektur TiCTok dengan teknik transformasi *embedding multi-view* sebagai cara untuk meningkatkan ketahanan dan konsistensi dalam representasi model. Optimasi ini diharapkan dapat mendorong batas kemampuan TikTok dalam mengidentifikasi pola anomali yang kompleks.

1.2 Rumusan Masalah

Berdasarkan latar belakang tersebut, terdapat beberapa rumusan masalah yang diangkat di penelitian ini, yaitu:

1. Bagaimana mekanisme transformasi *multi-view embedding* berbasis *Multi-Layer Perceptron* (MLP) diterapkan pada arsitektur model TiCTok dalam data *time-series* multivariat?
2. Bagaimana penerapan *multi-view embedding* memengaruhi kinerja deteksi anomali dan kualitas representasi laten dibandingkan model TiCTok baseline dalam data *time-series* multivariat?

1.3 Tujuan

Penelitian ini memiliki beberapa tujuan, yaitu:

1. Menerapkan mekanisme transformasi *multi-view embedding* berbasis *Multi-Layer Perceptron* (MLP) pada arsitektur model TiCTok dalam data *time-series* multivariat.
2. Menganalisis pengaruh penerapan *multi-view embedding* terhadap kinerja deteksi anomali dan kualitas representasi laten pada model TiCTok dibandingkan dengan model baseline.

1.4 Batasan Masalah

Dalam melakukan penelitian, terdapat beberapa batasan yang diterapkan, yaitu:

1. Metode yang digunakan adalah *self-supervised contrastive learning* tanpa menggunakan label anomali selama proses pelatihan, dan label hanya digunakan pada tahap evaluasi.
2. Pendeteksian anomali difokuskan pada anomali kolektif (*collective anomaly*) dalam data *time-series* multivariat.
3. Dataset yang digunakan adalah dataset publik *Server Machine Dataset* dengan jumlah 1.416.825 baris data, dengan 708.405 baris data *training* dan 708.420 baris data *testing* yang telah berada dalam bentuk *multivariate time-series metrics* [7], sehingga penelitian tidak mencakup proses ekstraksi fitur dari log mentah.
4. Transformasi *multi-view* dilakukan pada *embedding* laten (*latent representation*) yang dihasilkan model, menggunakan *Multi-Layer Perceptron* (MLP) sederhana, bukan pada data mentah atau pembagian fitur berbasis domain.
5. Penelitian tidak membahas tahap *feature extraction* dari *raw log*, *time-series forecasting*, maupun analisis akar penyebab (*root cause analysis*).

1.5 Manfaat

Dengan diadakannya penelitian ini, diharapkan dapat memberikan manfaat sebagai berikut:

1. Memberikan kontribusi akademik dalam pengembangan metode *self-supervised learning*, khususnya dalam analisis pengaruh transformasi *multi-*


view embedding terhadap stabilitas representasi pada data *multivariate time-series*.

2. Memberikan pemahaman mengenai pengaruh multi-view embedding terhadap robustness model anomaly detection pada lingkungan AIOps (*Artificial Intelligence for IT Operations*).
3. Menjadi referensi bagi penelitian selanjutnya dalam pengembangan metode representasi berbasis *contrastive learning* yang tidak bergantung pada interpretasi semantik fitur, melainkan pada pembelajaran representasi laten (*representation learning*).
4. Memberikan pemahaman mengenai *trade-off* antara stabilitas dan diskriminasi representasi dalam penggunaan *multi-view embedding* pada model *contrastive learning*.



1.6 Kerangka Penelitian

Penelitian dilakukan dengan menggunakan kerangka penelitian berikut:



SUNAN GUNUNG DJATI
Gambar 1. 1 Kerangka Berfikir

Penelitian ini dilatarbelakangi oleh empat permasalahan utama yang teridentifikasi dalam bidang TSAD pada infrastruktur IT. Pertama, model di bidang ini memiliki keterbatasan dalam mendeteksi anomali pada data *time-series multivariate* yang kompleks, karena anomali yang terjadi di sistem server tidak bisa terdeteksi hanya berdasarkan satu titik waktu saja [4]. Kedua, kebanyakan model yang tersedia saat ini masih menggunakan pendekatan berbasis rekonstruksi seperti *Autoencoder*, *LSTM*, dan *VAE*, yang tidak efisien karena membuang kapasitas belajar untuk merekonstruksi informasi yang tidak penting dalam mendeteksi anomali [5]. Ketiga, pendekatan pembelajaran *self-supervised* yang lebih baru masih bisa mengalami *representational collapse*, yaitu situasi di mana model mengumpulkan fitur yang berbeda ke dalam representasi yang terlalu seragam [5]. Keempat, kebutuhan akan model yang dapat berskala dan tahan terhadap gangguan dalam sistem pemantauan infrastruktur IT semakin mendesak, karena kegagalan

dalam mendeteksi masalah sekecil apa pun dapat menyebabkan kerugian finansial yang signifikan [1], [2].

Melalui analisis terhadap berbagai teknologi *state-of-the-art*, ditemukan bahwa setiap pendekatan yang ada memiliki keterbatasannya masing-masing. Model berbasis rekonstruksi (*Autoencoder*, LSTM, VAE) mampu mempelajari pola normal, namun tidak efisien dan kurang *robust* [5]. Pendekatan *Contrastive Learning-based* TSAD seperti CPC-AD [9], CL-TAD [10], DCdetector [11], dan CARLA [12] menunjukkan bahwa representasi laten bisa dipelajari tanpa rekonstruksi, namun masih sensitif terhadap augmentasi dan sampling. Model TiCTok [5] menjadi salah satu model terkuat saat ini berkat kombinasi tokenisasi, *CNN encoder*, dan *Transformer autoregressive* dengan skema *Contrastive Predictive Coding* (CPC) yang efektif menangkap *long-range temporal dependency* [5], namun masih menggunakan *single-view embedding* sehingga berisiko mengalami *representational collapse*. Di sisi lain, pendekatan *Multi-View Embedding* seperti CNT [8] terbukti meningkatkan stabilitas representasi dan mencegah *collapse*, tetapi belum mengintegrasikan mekanisme tokenisasi dan pemodelan *temporal autoregresif* yang menjadi keunggulan TiCTok.

Gap penelitian yang ditemukan adalah belum adanya pendekatan yang menggabungkan kekuatan pemodelan temporal jangka panjang melalui tokenisasi (TiCTok) dengan stabilitas representasi melalui *multi-view embedding* dalam satu *framework* yang terpadu. Oleh karena itu, solusi yang diusulkan dalam penelitian ini adalah integrasi arsitektur TiCTok dengan mekanisme transformasi *multi-view embedding* pada level representasi laten untuk menghasilkan representasi yang lebih stabil, variatif, dan diskriminatif.

Secara implementasi, model bekerja dengan menerima input berupa data *sliding window* dari *Server Machine Dataset* (SMD) [7] yang berisi 38 metrik operasional dari 28 mesin server. Setiap window diproses melalui dua *CNN Encoder* untuk menghasilkan *local representation*, dilanjutkan dengan *Transformer* untuk *temporal modeling*, kemudian diproyeksikan ke dua ruang *embedding* berbeda menggunakan *MLP Projector (multi-view)*, dan dilatih menggunakan *Contrastive Learning* CPC dengan fungsi kerugian InfoNCE [12], [13]. Nilai *contrastive loss* digunakan langsung sebagai *anomaly score*. Model kemudian dievaluasi dengan membandingkan performa baseline TiCTok dengan model yang diusulkan menggunakan metrik *Precision*, *Recall*, dan *F1-Score* untuk metrik kinerja deteksi anomali dan *Alignment Loss*, *Uniformity Loss*, dan *Effective Rank* untuk metrik kualitas representasi laten dengan target akhir menghasilkan model deteksi anomali yang lebih diskriminatif dan stabil untuk kebutuhan monitoring infrastruktur IT secara *real-time*.