

זיהוי אירועים חריגים בטורבינת גז



נתונים. תובנות. פעולה בזמן אמת.

מטרות

להציג שיטות גילוי של:

- חריגות רגעיות
- הידרדרות איטית
- שילובים נדירים של משתנים

להציג את עקרונות
מערכת MicroEDS
לזיהוי חריגות בטורבינות
גז.

להבין כיצד משלבים
למידת מכונה בלתי
מונחית עם חוקים
הנדסיים.

להדגים כיצד מערכת
יוצרת אירועים EDS
מתוך דטקטורים.

להציג מקרה בוחן מבוסס
נתוני טורבינת גז.

הבנת תהליך בניית
detectors.

הבנת שימוש בטבלאות
צפיפות.

יישום

שימוש בכלי AI להאצת
התהליך וקבלת משוב

אודות המרצה והחברה



כובע אקדמי



- תואר שלישי מהאוניברסיטה העברית בתחום כלכלה חקלאית



- פוסט דוק באוניברסיטת מרילנד



- חבר סגל בפקולטה להנדסת תעשייה וניהול - מכון טכנולוגי חולון משנת 2007



כובע מסחרי



- בעלים של חברת מקבלי החלטות בע"מ שעוסקת בתחום של למידת מכונה בזמן אמת.



- פרויקטים בתחום מים, סולארי, תעשייה.



- פעילות משנת 2007



מים



סולארי



תעשייה



פתרונות מבוססי למידת מכונה לאיתור חריגות בזמן אמת

סוגים של למידת מכונה

תוכנית מחשב נחשבת ככזו שלומדת מניסיון אם ביצועיה משתפרים עם הצטברות הניסיון.

Tom M. Mitchell 2015.

למידה בלתי מונחית מאפשרת גילוי דפוסים וקשרים חדשים ללא שימוש בתוויות שנוצרו על ידי אדם.

Yanshan Wang 2017.

הרעיון שאנו לומדים באמצעות אינטראקציה עם הסביבה הוא כנראה הדבר הראשון שעולה בדעתנו כאשר אנו חושבים על טבע הלמידה.

Richard S. Sutton ו-Andrew G. Barto

The infographic is divided into three horizontal sections, each with a title, a diagram, and a list of characteristics.

- Supervised Learning:** The diagram shows a computer monitor with a scatter plot of blue and orange dots separated by a dashed diagonal line, with an arrow pointing to a list of three items with checkmarks. The text below the diagram lists: "המערכת מקלת הנמאה מתינות.", "דוגמא:", "תקין", "כשל מרחס", and "בעירת יתר".
- Unsupervised Learning:** The diagram shows a cloud containing three clusters of dots (blue, orange, and green) with an arrow pointing to a magnifying glass over a bar chart. The text below the diagram lists: "אין תיוגים.", "המערכת לומדת את המבנה הסטטיסטי של הנתונים", "מתאימה במיוחד לטורבינות זו:", "מעט תקלות אמיתיות", and "הרבה נתונים תקינים".
- Reinforcement Learning:** The diagram shows a robot in the center with arrows pointing to four icons: a gauge labeled "מצב", a checkmark labeled "פעולה", a star labeled "תגמול", and a target icon. The text below the diagram lists: "אין תיוגים בשלבי הביניים, רק בסוף התהליך".

מדוע MicroEDS משתמש בעיקר ב- Unsupervised Learning?

אירועים נדירים.



קשה להשיג דוגמאות לכשל.



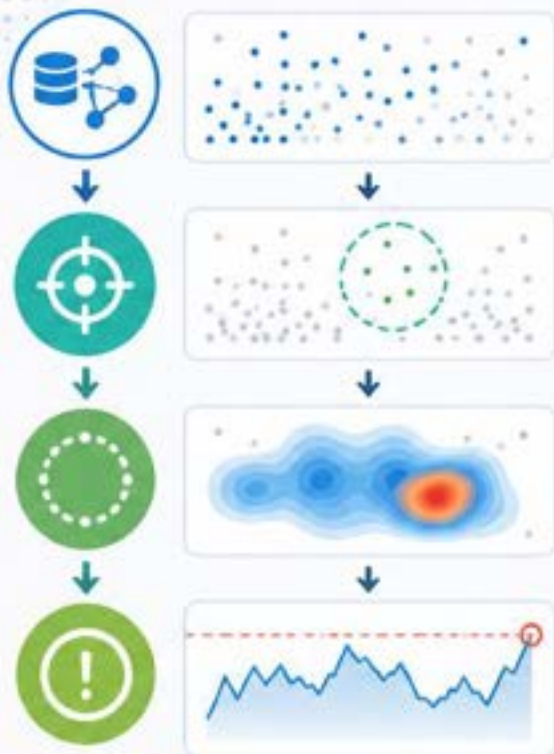
שוני בין הפריטים (כל טרבינה שונה מעט).



תנאי עבודה משתנים לאורך זמן.



מתודולוגיה "רגילה לאיתור חריגות"



1 מבצעים קלסטריזציה של הנתונים



1

2 מזהים כאשר "קלסטר" נמצא באזור "לא טוב" או באזור בעייתי



2

3 כאשר מופיעות נקודות באזור שבו לא קיים קלסטר.



3

4 דוגמא: זיהוי רכישה חריגה.



4



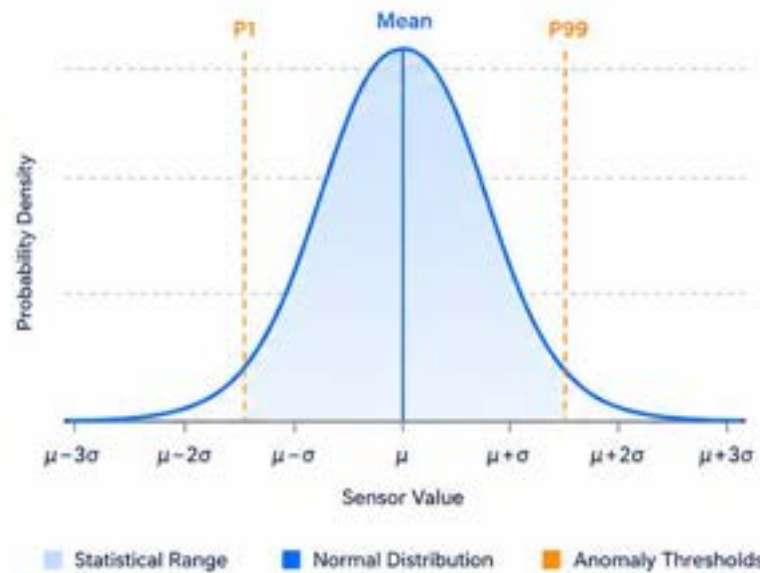
הגישה נשענת על הנחה שקיימת מבנה תקין (קלסטרים) וחריגות הן סטיות ממבנה זה.

מדוע לא ישים במקרה של זמן אמת:



שיטות מסורתיות לאיתור חריגות אינן יכולות להתמודד עם הדרישות של זמן אמת.

STATISTICAL PROPERTIES OF



VALID RANGE

Hardware-defined physical limits of the sensor (e.g., 0–1400°C for Type K thermocouples).

STATISTICAL RANGE

AI-learned normal operating envelope (e.g., 450–620°C during steady-state baseload).

GOOD RANGE

Optimal operating band for peak thermal efficiency and minimal component wear.

PERCENTILES

Learned distribution metrics (P1, P5, P50, P95, P99) defining anomaly thresholds.

CENTRAL TENDENCY

Mean and median calculations for identifying baseline sensor drift over time.


STANDARD DEVIATION

Measurement of signal spread; used to calculate dynamic N-Sigma detection bounds.



Minimal Change of Interest (MCI): The smallest meaningful change (e.g., 2°C for exhaust gas) that prevents detector triggering on background signal noise.

THREE LAYERS OF BOUNDS



VALID RANGE

Hardware-defined physical limits of the sensor.
Outer boundary of all possible values.



STATISTICAL RANGE

AI-learned normal operating envelope based on historical data (e.g., steady-state baseload).



GOOD RANGE

Optimal operating band for peak efficiency and minimal component wear.
Most desirable region.

LIMIT DETECTION: REGULAR vs. STATISTICAL



REGULAR LIMIT DETECTOR

- Objective:** OEM design limit protection.
- Threshold:** Fixed engineering values.
- Application:** Critical safety trips (EGT > 650°C).



STATISTICAL LIMIT DETECTOR

- Objective:** Early anomaly identification.
- Threshold:** Learned distribution (P5 to P95).
- Application:** Compressor discharge pressure drift.

OPERATIONAL DATA VS. MONITORING BOUNDARIES

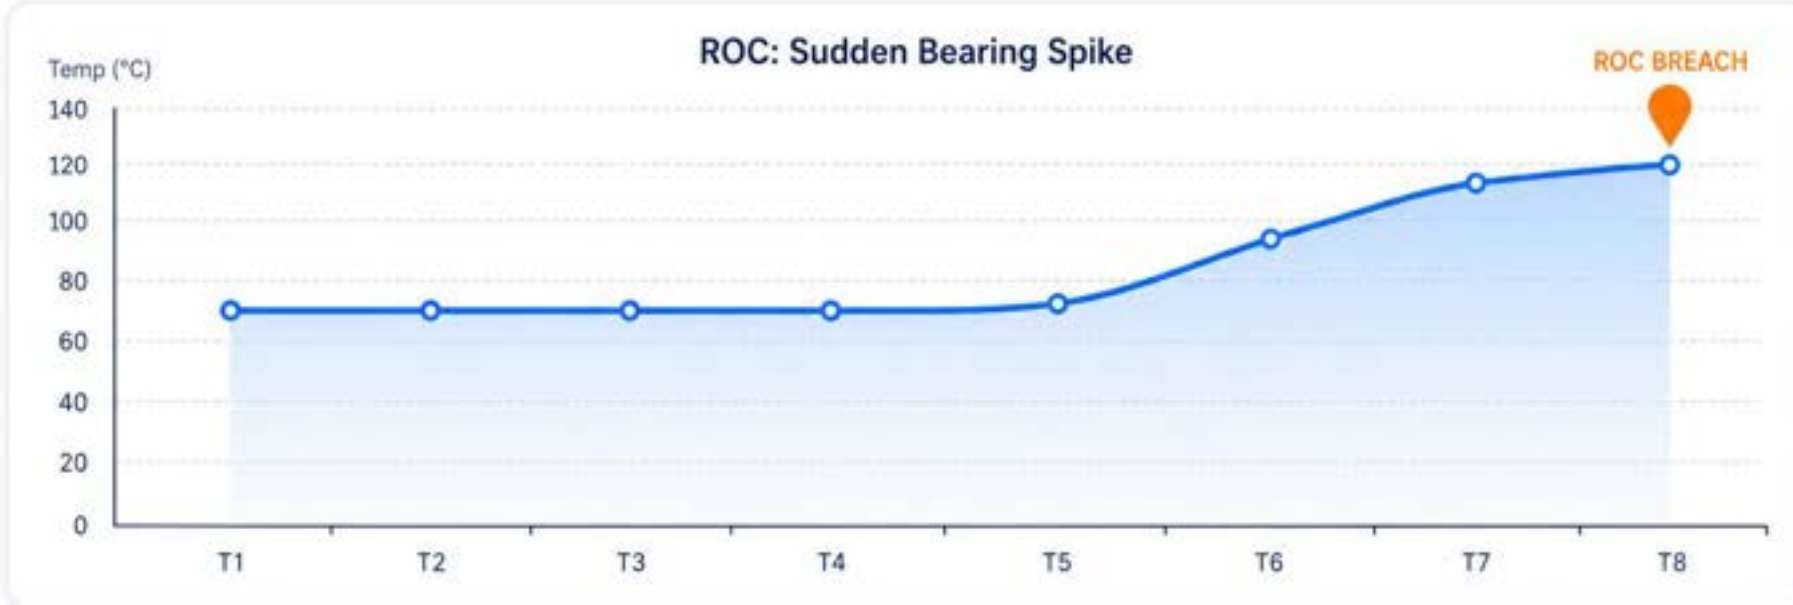


Statistical limits adapt to normal behavior and detect subtle drifts early, **before** fixed limits are reached.



RATE-OF-CHANGE (ROC)

Detect rapid changes. Act before it's too late.



Purpose:

Identifies abnormally rapid signal variations by monitoring the derivative of sensor input over time.



Turbine Use Case:

Detecting sudden bearing temperature rises ($>5^{\circ}\text{C}/\text{min}$) indicating critical lubrication system failure.



Advantage:

Triggers alarms before absolute limits are breached, providing critical seconds for emergency shutdown.




Why it matters: ROC detects dangerous trends early— **not just when limits are exceeded.**



LONG TREND DETECTOR

Monitor gradual changes. Plan maintenance. Prevent outages.



PURPOSE

Monitors slow, persistent drifts in mean values over days or weeks using advanced moving averages.



TURBINE USE CASE

Tracking gradual **compressor efficiency decline** caused by environmental fouling or blade erosion.



OUTCOME

Enables condition-based maintenance scheduling, optimizing fuel consumption and preventing forced outages.



EARLY INSIGHT.

Detect degradation early.



BETTER DECISIONS.

Plan maintenance smartly.



HIGHER RELIABILITY.

Avoid outages. Save cost.





NOISE DETECTOR

Detect hidden instability. Act before it escalates.

Monitors high-frequency signal variability and statistical variance. Identifies changes in the underlying stochastic process rather than absolute magnitude shifts.

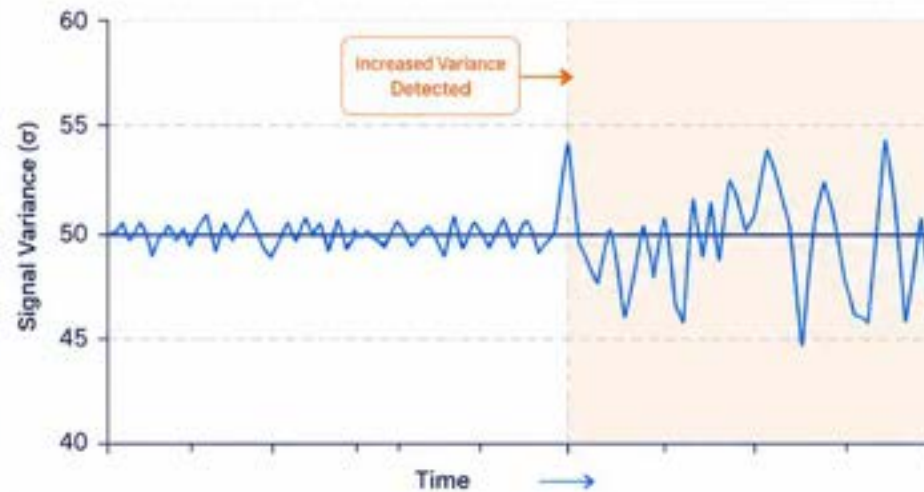
- Detects increased signal jitter/flutter
- Analyzes standard deviation over sliding windows
- Filters out low-frequency process changes



GT USE CASE:

Bearing wear identification or combustion instability prior to high-vibration trips.

SIGNAL VARIANCE INCREASE (ANOMALY)



WHAT IT MONITORS

High-frequency variability in sensor signals that indicates process noise or instability.



HOW IT WORKS

Calculates standard deviation over a sliding window and tracks variance trends.



WHAT IT DETECTS

Increased jitter, flutter, or turbulence that precedes mechanical or combustion issues.



WHY IT MATTERS

Detects problems early—before they cause alarm thresholds to be exceeded.



THE OUTCOME

Earlier interventions, reduced downtime, and improved equipment reliability.



Noise changes speak first. | Noise Detector helps you listen early, act early, and stay ahead.



FROZEN SENSOR DETECTOR

Detect stuck sensors. Protect data integrity.

Identifies "frozen" or "stuck" sensors by monitoring signal variance. Triggers when a signal remains perfectly constant over a defined period (unnatural for active sensors).



Identifies frozen A/D converter outputs



Detects sensor software communication locks



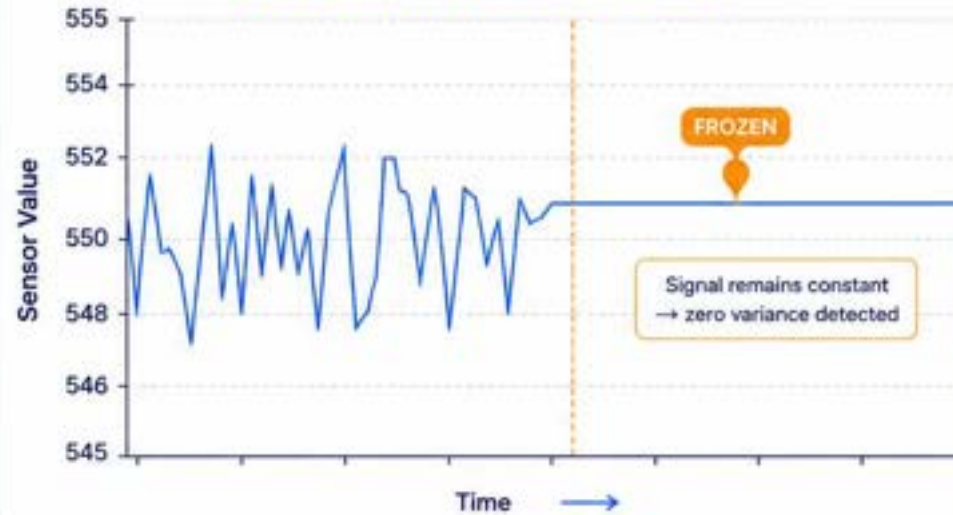
Essential for maintaining monitoring integrity

GT USE CASE:



Thermocouple reading frozen at last value before failure, preventing false "stable" readings.

ZERO VARIANCE (SENSOR FAILURE)



WHAT IT MONITORS

Signal variance over time to detect when a sensor output becomes unnaturally constant.



HOW IT WORKS

Calculates variance in a sliding window. When variance falls to (near) zero → alarm.



WHAT IT DETECTS

Frozen A/D outputs, communication locks, or sensor software hangs.



WHY IT MATTERS

Prevents false confidence in "stable" readings and protects monitoring integrity.



THE OUTCOME

Early detection of stuck sensors reduces risk, improves reliability, and prevents downtime.



Good data begins with healthy sensors.

Detect frozen signals before they hide real problems.





MULTIVARIATE RARITY DETECTOR

Detect rare combinations. Understand what's normal.



Monitors groups of related sensors to detect unusual combinations that are not seen before.



Each combination has a timestamp, so we know when we didn't see it before.



Detects rare multivariate combinations not seen in historical data.



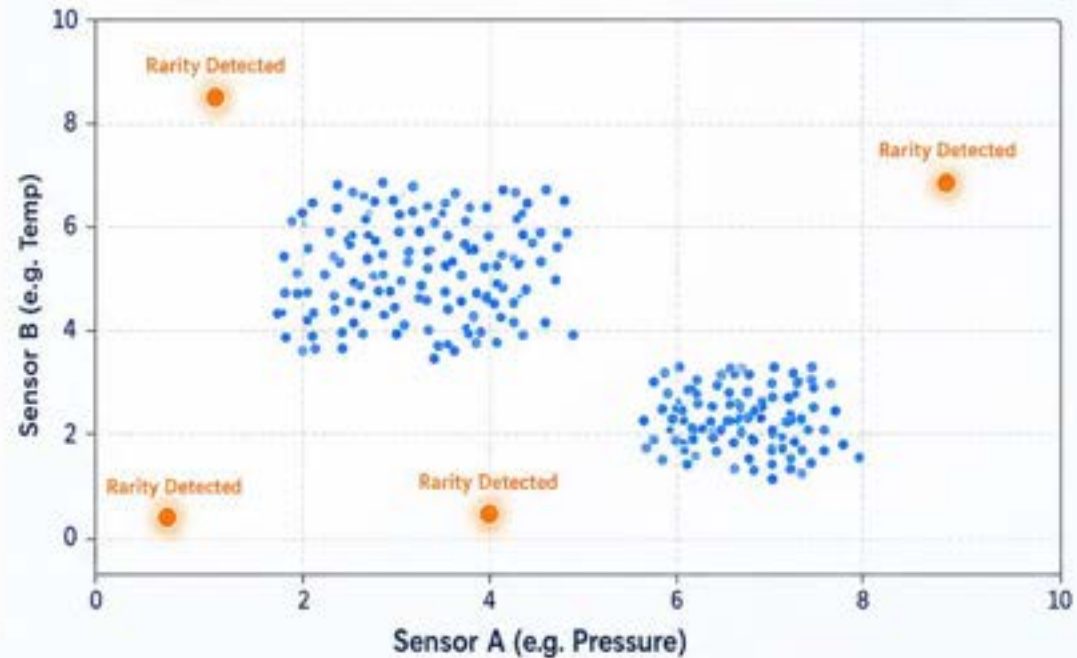
Identifies outliers in multi-sensor space, not just single-sensor anomalies.



Improves operational awareness and supports faster root cause analysis.



The clusters represent common operating conditions. Points in orange are rare combinations we haven't seen before.



1. LEARN NORMAL

Build a model of historical multi-sensor combinations.



2. MONITOR IN REAL TIME

Continuously evaluate new combinations as they occur.



3. DETECT RARE

Flag combinations that deviate from known patterns.



4. ALERT & INVESTIGATE

Investigate rare events to prevent issues and improve reliability.



See the unknown. Prevent the unexpected.

Detect rare combinations across sensors before they become problems.

מהי טבלת צפיפות (Density Table)?

טבלת צפיפות היא מפת המצבים של המערכת המבוססת על נתונים היסטוריים

כל תא (Cell) מייצג טווח ערכים של מספר משתנים, והצפיפות היא מספר הפעמים שנצפה מצב דומה בעבר

1. המרת ערכים לאינטרוולים

כל משתנה מחולק לאינטרוולים (טווחים)

pH	כלור (Cl)	טמפר' (°C)
6.0 - 6.5 → 1	0 - 0.2 → 1	10 - 15 → 1
6.5 - 7.0 → 2	0.2 - 0.4 → 2	15 - 20 → 2
7.0 - 7.5 → 3	0.4 - 0.6 → 3	20 - 25 → 3
7.5 - 8.0 → 4	0.6 - 0.8 → 4	25 - 30 → 4
8.0 - 8.5 → 5	0.8 - 1.0 → 5	30 - 35 → 5
...

דוגמה

pH = 7.05 → אינטרוול 3
 Cl = 0.35 → אינטרוול 2
 Temp = 22°C → אינטרוול 3

2. יצירת מפתח תא (Cell Key)

לכל דגימה נוצר מפתח תא (Key)
 המפתח הוא משלב מספרי האינטרוולים של כל המשתנים

pH	Cl	Temp	Cell Key
3	2	3	3 2 3
3	2	3	3 2 3
2	2	3	2 2 3
3	3	3	3 3 3
3	2	4	3 2 4
...

מפתח תא (Cell Key)

3 | 2 | 3

↓ ↓ ↓

אינטרוול של טמפר' אינטרוול כלור אינטרוול pH

3. טבלת צפיפות (Density Table)

סופרים כמה פעמים הופיע כל מפתח תא (Key)
 (GROUP BY KEY, COUNT(*))


Cell Key	צפיפות (מס' מופעים)
3 2 3	1,240
2 2 3	950
3 3 3	780
3 2 4	410
2 1 3	120
4 3 4	8
1 1 1	1
...	...

מקרא

- צפיפות גבוהה מצב מוכר ותיקין
- צפיפות בינונית מצב נדיך
- צפיפות נמוכה מצב חריג
- 0 לא נצפה מעולם

למה זה חשוב?

- אירוע חריג אינו תמיד קיצון של ערך בודד, אלא צירוף לא מוכר של מספר משתנים יחד.
- המערכת מזהה מצבים חריגים גם כאשר כל משתנה נראה תקין בנפרד.



כך זה עובד בזמן אמת

- נמדדים הערכים הנוכחיים של כל המשתנים
- מערכים לאינטרוול ומחזרים את מפתח התא
- בודקים את הצפיפות בטבלה
- צפיפות נמוכה → התראה (אירוע חריג)

GAS TURBINE DATASET OVERVIEW

Variables, Categories and Measurements

DATASET SUMMARY


Time Resolution
1 minute

Total Variables
40+

Data Sources
SCADA / DCS

Operating Data
Continuous

Typical Units
Standard industrial units



KEY MONITORING AREAS

- Combustion Stability**
T5 sensors, T7 average
- Mechanical Health**
Vibration sensors, gearbox vibration
- Thermodynamic Efficiency**
Compressor pressure, fuel flow
- Lubrication Integrity**
Lube oil pressure/temp
- Electrical Stability**
Voltage, current, frequency
- Airflow Restriction**
Filter differential pressures

TIME & OPERATING COUNTERS

- Hour_Time (hr)
- Gas_fuel_fired_hours (hr)
- Liquid_fuel_fired_hours (hr)
- Turbine_hours_ (hr)
- Start_count (count)

5 Variables

COMPRESSOR SYSTEM

- Compressor_inlet_air_temp (°C)
- Compressor_T5_average (°C)
- Turbine_air_inlet_filter_DP (kPa/mbar)
- Compressor_outlet_air_pressure (bar/kPa)

4 Variables

FUEL SYSTEM

- Gas_fuel_flow (Nm³/hr or kg/hr)
- Gas_fuel_pressure_1 (bar/kPa)
- Liquid_fuel_flow_kg/min (kg/min)
- Liquid_fuel_inlet_pressure (bar/kPa)
- Gas_Fuel_Control_Temperature (°C)

5 Variables

LUBRICATION SYSTEM

- Lube_oil_pressure_ (bar/kPa)
- Lube_oil_temperature (°C)

2 Variables

VIBRATION & MECHANICAL HEALTH

- Turbine_vibration_X1 (mm/s)
- Turbine_vibration_Y1 (mm/s)
- Turbine_vibration_2_X (mm/s)
- Turbine_vibration_2_Y (mm/s)
- Turbine_vibration_3_X (mm/s)
- Turbine_vibration_3_Y (mm/s)
- Gearbox_vibration (mm/s RMS)

7 Variables

ELECTRICAL GENERATOR

- Voltage (V/kV)
- Current_A/B/C (A)
- Real_power_ (MW/kW)
- Apparent_power (MVA/kVA)
- Reactive_power_ (MVar/kVar)
- Power_factor (-)
- Frequency (Hz)
- Generator_excitation_current (A)

9 Variables

TURBINE TEMPERATURES

- Turbine_temperature_T5_#1 ... #6 (°C)
- Turbine_Exhaust_temperature_T7_ (Average) (°C)

7 Variables

ENVIRONMENT / ENCLOSURE

- Ceiling_temperature (°C)

1 Variable

GENERATOR BEARINGS

- Generator_DE_bearing_temperature_ (°C)
- Generator_NDE_bearing_temperature_ (°C)

2 Variables

GENERATOR WINDING TEMPERATURES

- Generator_L1_winding_temperature (°C)
- Generator_L2_winding_temperature (°C)
- Generator_L3_winding_temperature (°C)

3 Variables

PNEUMATICS & INSTRUMENTATION

- Instrument_Air_Pressure (bar/kPa)

1 Variable

AIR FILTRATION SYSTEM

- Enclosure_Main_Filter_DP (Pa/mbar/kPa)
- Turbine_Air_Inlet_Filter_DP2 (Pa/mbar/kPa)
- Turbine_Air_Inlet_Pre_Filter_DP (Pa/mbar/kPa)
- Turbine_Air_Inlet_PrePre_Filter_DP (Pa/mbar/kPa)

4 Variables



TOTAL: 40+ VARIABLES

Covers All Major Subsystems of a Simple Cycle Gas Turbine

Enables Comprehensive Performance Monitoring, Diagnostics and Anomaly Detection

Supports Predictive Maintenance and Operational Optimization



צירופים !



יותר נתונים = יותר תובנות = זיהוי מוקדם יותר



במערך נתונים של 50 משתנים,

50
משתנים



יש 249,900 צירופים של ארבעה משתנים.

249,900
צירופים



יש 2,349,060 צירופים של חמישה משתנים.

2,349,060
צירופים



יש 18,009,460 צירופים של שיישה משתנים.

18,009,460
צירופים



ממוקדים במה שחשוב

כיצד בוחרים את הצירופים הרלוונטיים לטבלאות הצפיפות ?



מצמצמים רעש




מבוססים על ידע ותובנות



מובילים לתובנות מדויקות וזיהוי מוקדם יותר

קיבוץ אוטומטי של משתנים לטבלאות צפיפות

DensityTableGrouperApp לוגיקת קבלת ההחלטות בתוכנית



פרמטרים שמכתיבים את ההחלטה: `threshold = 0.60` רשומות `maxLag = 5` `maxGroupSize = 4` הממד החזק ביותר = הציון לזוג

גרף קשרים → מטריצת דמיון

רכיב קשיר מעל הסף הופך לטבלת צפיפות




































מה התוכנית מחליטה אחרי הקיבוץ

א	כיסוי הנדסי	ב	דירוג משתנים	ג	הסבר לזיהוי
	סיווג לפי שם המשתנה חשמל וכו', שמן, רעידות, דלק, מדחס		ממוצע הדמיון שלו = ציון לכל משתנה לשאר משתני הקבוצה		הדגש — אם יש כמה תתי-מערכות בין תחומים Rare Combination הוא

ולכן מתאימות לגילוי אזורים נדירים בטבלת צפיפות — התוכנית מחפשת קבוצות משתנים שמתנהגות יחד, במקום לבדוק חריגה של משתנה יחיד: רעיון מרכזי

טבלאות צפיפות מומלצות לטורבינת גז – קבוצות משתנים ויעד כל טבלה

כל טבלה מייצגת מערכת פיזיקלית מרכזית ומאפשרת זיהוי מוקדם של סטיות עדינות

תחום	טבלה צפיפות מומלצת	משתנים	מטרה עיקרית
 יעילות מדחס Compressor Performance	 load_pct  ambient_temp_C  air_flow_kg_s	 compressor_pressure_ratio  compressor_discharge_temp_C  heat_rate_kJ_kWh	 ניטור ביצועי מדחס וזיהוי ירידה בעילות, זיהום, ריסון או סתם
 יציבות בעירה Combustion Stability	 fuel_gas_flow_kg_s  turbine_inlet_temp_C  exhaust_temp_C	 exhaust_o2_pct  co_ppm  nox_ppm  combustion_dynamic_pressure_kPa	 ניטור איכות ותהליך הבעירה וזיהוי חוסר איזון, חום חריג או בעיות בפליטות
 מיסבים ושימון Bearing & Lubrication	 load_pct  lube_oil_pressure_kPa  lube_oil_temp_C	 bearing_1_temp_C  bearing_2_temp_C  bearing_1_vibration_mm_s  bearing_2_vibration_mm_s	 ניטור מערכת השימון ומהימנות מיסבים וזיהוי תחילת בלאי, חימום חריג או רעידות מתפתחות
 תגובה דלק-הספק Fuel-to-Power Response	 load_pct  fuel_gas_flow_kg_s  generator_power_MW  generator_current_A	 turbine_inlet_temp_C  exhaust_temp_C  shaft_speed_rpm	 ניטור תגובת המערכת לפקודות הספק וזיהוי תקיעות שסתומים, בעיות במערכת הדלק או דריפט



שילוב המשתנים בכל טבלה מאפשר למערכת EDS לזהות שלובים נדירים של ערכים (צפיפות נמוכה) גם כאשר כל משתנה בודד נמצא בתחום תקין של SCADA.

כך מתאפשר גילוי מוקדם של תקלות עדינות לפני הופעת אזעקות.

1 אירוע

GRADUAL COMPRESSOR FOULING / INLET-PATH EFFICIENCY LOSS



זיהום מדחס / ירידה ביעילות נתיב היניקה

תיאור האירוע



הצטברות הדרגתית של מזהמים במסנן הכניסה ובנתיב היניקה גורמת לירידה ביעילות המדחס. האירוע מתפתח לאט לאורך זמן וקשה לזיהוי באמצעות SCADA בלבד.

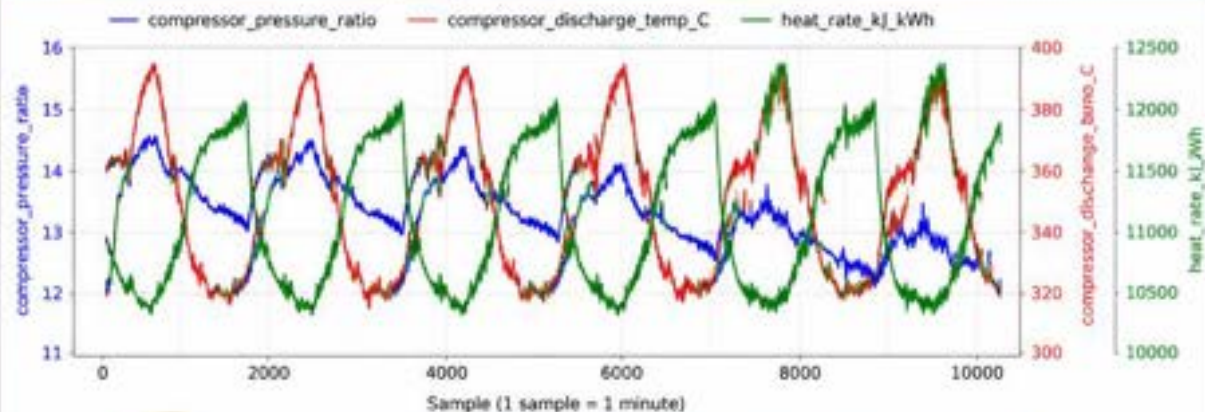
שינויים מתואמים (עדינים)

- עלייה קלה בטמפרטורת יציאת המדחס ↑
- ירידה קלה ביחס לחצים (Pressure Ratio) ↓
- ירידה קלה בזרימת האוויר ↓
- עלייה קלה בצריכת חום (Heat Rate) ↑



כל המשתנים נשארים בתוך גבולות תקינים של SCADA

מגמות המשתנים לאורך הזמן




מגמות עדינות ומתואמות לאורך מאות שעות – לא מזהות ע"י SCADA

משתנים עיקריים בטבלת צפיפות מס' 1

משתנה	תיאור	כיוון שינוי באירוע
compressor_pressure_ratio	יחס לחצים במדחס	↓
compressor_discharge_temp_C	טמפרטורת יציאת המדחס (°C)	↑
air_flow_kg_s	זרימת אוויר (ק"ג/שני)	↓
heat_rate_kj_kWh	צריכת חום (ק"ג/קו"ס"ש)	↑
ambient_temp_C	טמפרטורת סביבה (°C)	—
load_pct	עומס (%)	—

זיהוי באמצעות EDS (PCA)

מבט דו-ממדי של המשתנים



מה מזהה מערכת EDS?



שילוב נדיר של המשתנים יחד



- סטטייה רב-משתנית עדינה ✓
- אינה מזהה ע"י SCADA ✓
- ימזהה מוקדם ע"י EDS ✓



גילוי מוקדם מאפשר מניעת ירידה בהספק ותקלות עתידיות



סיכום: זיהום מדחס מתפתח לאט ומשפיע על מספר מדדים בו-זמנית. טבלת הצפיפות מזהה את השילוב הבלתי-שגרתי לפני שהערכים חורגים מגבולות התקינים של SCADA – ומאפשרת התראה מוקדמת ותחזוקה ממוקדת.

ניתוח רכיבים עיקריים – PCA

Principal Component Analysis



PCA היא טכניקה סטטיסטית שמטרתה לצמצם את מימדיות הנתונים תוך שמירה על מירב המידע האפשרי. היא יוצרת משתנים חדשים (רכיבים עיקריים) שהם שילובים ליניאריים של המשתנים המקוריים, בלתי מתואמים זה לזה, וממוינים לפי כמות השונות (מידע) שהם מסבירים.


למה משתמשים ב-PCA?

- ✓ צמצום מימדיות של נתונים רבים משתנים
- ✓ הדגשת התבניות והקשרים המרכזיים
- ✓ הסרת רעש ומידע מיותר
- ✓ ויזואליזציה של נתונים מרובי משתנים.
- ✓ שיפור ביצועים במוודלים ובגילוי אנומליות.

איך עובד? (ב-5 שלבים)




דוגמה ויזואלית



נמצא נמצא את הכיוונים החשובים ביותר בנתונים ומקרין עליהם, כך שהמידע ממרכזי נשמר גם במרחב מצומצם.

כמה שונות כל רכיב מסביר?



בדרך כלל בוחרים את מספר הרכיבים במקום שבו העקומה מתיישרת (ה"תשואה השולית" של רכיב נוסף כבר נמוכה).
בדוגמה: 2-3 רכיבים מסבירים ~90% מהמידע.

נוסחה מתמטית

הרכיב העיקרי ה-k הוא שילוב ליניארי של המשתנים המקוריים:

$$PC_k = w_{k1}X_1 + w_{k2}X_2 + \dots + w_{kn}X_n$$

כאשר w_{kj} הם המשקלים (הווקטור העצמי) שקובעים את תרומת כל משתנה לרכיב.

שימושים נפוצים

- נילי אנומליות במרחב מצומצם
- צמצום מימדיות לפני מודלים
- הבנת מבנה והיחלות בנתונים
- ויזואליזציה של נתונים רבים משתנים



PCA אינו משפר את איכות הנתונים – הוא רק מציג אותם בצורה הכמה יותר. הפרשנות ההנדסית של הרכיבים חשובה להבנת המשמעות הפיזיקלית של התבניות.

1 אירוע

שינוי במצב המערכת

תזוזה ב - PCA – מצב במערכת

השוואה בין התפלגות מצבי מערכת נורמלית להתפלגות במצב אירוע



מה רואים בגרף?

הגרף מציג את ההתפלגות של הנתונים במרחב PCA לפני האירוע (כחול) ואחרי האירוע (אדום).

נקודות אדומות רבות נמצאות רחוק ממרכז הנורמלי (הכחול) – עדות לכך שהמערכת עובדת אחרת.



איך מפרשים את התזוזה?

תזוזה אופקית (בכיוון PC1):
שינוי בעיקר במשתנים המתוארים על ידי PC1 (הרכיב שמסביר את מרבית השונות).



תזוזה אנכית (בכיוון PC2):
שינוי בעיקר במשתנים המתוארים על ידי PC2 (הרכיב השני בחשיבותו).




תזוזה אלכסונית:
שינוי משולב במספר קבוצות משתנים בו-זמנית.

מה מייצגים הסמנים?

✘ מרכז נורמלי (ממוצע מצב תקין) – נקודת ייחוס.

✘ מרכז אירוע (ממוצע בזמן אירוע) – מצב חדש.

הבדל בין PCA הראשון לבין השני



ככל שהמרכז של מצב האירוע (אדום) רחוק יותר ממרכז המצב הנורמלי (כחול), כך השינוי במערכת משמעותי יותר.



המשמעות:

EDS | ששתמש הרחק לבחן (Mahalanobis) במרחב PCA כדי להעריך עד כמה המצב הנוכחי שונה מהמצב הנורמלי, ולזהות אירועים עוד לפני שכל משתנה בודד חורג מגבולות SCADA.



דוגמה ליישום:

- ניטור רציף של מרחק בזמן אמת מהמוצע הנורמלי ✓
- התראה כאשר המרחק חורג מסף שנקבע ✓
- איתור מוקדם של תקלות מתפתחות ✓

2 אירוע שינוי במצב

COMBUSTION IMBALANCE / WEAK BURNER DYNAMICS



חוסר איזון בעירה / דינמיקה חלשה של המבער

תיאור האירוע




חוסר איזון בעירה או דינמיקה חלשה של המבער גורמים לשינויים מתואמים במספר מדדי בעירה. השינויים עדינים ואינם חורגים מגבולות אזעקה של SCADA, אך מעידים על הידרדרות ביציבות הבעירה.

שינויים מתואמים (עדינים)

- עלייה קלה בדינמיקת הבעירה (לתך תנודתי) ↑
- עלייה ב-CO ↑
- התפשטות/עלייה בטמפרטורת הפליטה (T7) ↑
- שינויים קטנים ב-O₂ ו-NOx ↑

✓ כל המשתנים נשארים בתוך גבולות תקינים של SCADA

מגמות המשתנים לאורך הזמן

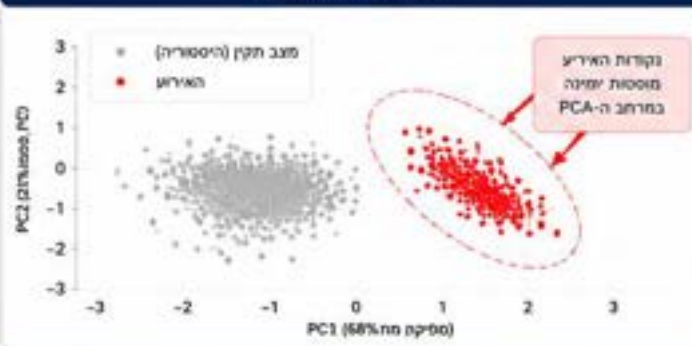


מגמות עדינות ומתואמות לאורך זמן – לא מזוהות ע"י SCADA

משתנים עיקריים בטבלת צפיפות מס' 2

משתנה	תיאור	מצבון בריכוז באירוע
combustion_dynamic_pressure_kPa	לתך תנודתי בתא הבעירה	↑
co_ppm	ריכוז פחמן חד-חמצני	↑
exhaust_temp_C	טמפרטורת הפליטה (T7)	↑
nox_ppm	תחמוצות חנקן	↓
exhaust_o2_pct	אחוז חמצן בגדי הפליטה	↑
fuel_gas_flow_kg_s	ספיקת דלק בזי	—

זיהוי באמצעות PCA (שני רכיבים ראשיים)



השינוי המתואם במספר גורמים יוצר דפוס נדיר במרחב – מזוהה ע"י EDS

מה מזהה מערכת EDS?

שילוב נדיר של שינויים מתואמים במספר מדדי בעירה

- ✓ סטייה רב-משתנית עדינה
- ✓ אינה מזוהה ע"י SCADA
- ✓ מזוהה מוקדם ע"י EDS

גילוי מוקדם מאפשר כיוון המבער/דלק, מניעת התדרדרות ובמניעת איבוד יעילות



סיכום: חוסר איזון בעירה יוצר שינויים קטנים ומתואמים במספר מדדי בעירה. כל מדד בודד נראה תקין, אך שילובם מזהה דפוס חריג – זוהה במערכת EDS לפני שנדרשת התערבות.



תזוזת PCA – מה רואים ולמה זה חשוב?

השוואה בין מצבי פעולה: תקין לעומת אירוע (תקלה)



מה זה PCA?

PCA הוא שיטת ניתוח שמצמצמת מספר רב של משתנים לשני רכיבים עיקריים (PC1, PC2) שמבירים את מרבית השונות בנתונים ומאפשרים לראות את המצב הכללי של המערכת במרחב דו-ממדי.

מה מייצגת כל נקודה?

נקודה כחולה – מצב תקין (Normal PCA)
התנהגות רגילה של המערכת.



נקודה אדומה – מצב אירוע (Event PCA)
התנהגות המערכת בזמן חז תקלה או אי-תקינות.



מרכזים (Centroids)


הממוצע של כל הנקודות בכל מצב – מייצג את "המיקום הטיפוסי" של כל מצב במרחב.



איך קוראים את הגרף?

- הנקודות הכחולות מרוכזות בעיקר בחלק התחתון (ערכי PC2 נמוכים).
- הנקודות האדומות ממוקמות גבוה יותר (ערכי PC2 גבוהים).
- קיים חפיפה מסוימת, אך המרכזים (X) רחוקים זה מזה – מעיד על שינוי משמעותי במצב המערכת.
- ככל שהמרחק בין המרכזים גדול יותר – כך ההבדל בין המצבים משמעותי יותר.

תזוזת PCA בין מצב תקין למצב אירוע



מה המשמעות?



המערכת בזמן אירוע מתנהגת באופן שונה באופן משמעותי מההתנהגות התקינה.



PCA מאשר לזהות שינוי כולל גם כאשר כל משתנה בנפרד עדיין בתחום ה-SCADA התקין.



הסטייה הכוללת במרחב היא מימן מוקדם לאירוע – עוד לפני הופעת התראת תקלה.



גילוי מוקדם = התראה מוקדמת, מניעת נזקים, ושיפור זמינות וביצועי המערכת.



PCA משולב מידע מכל המשתנים יחד ומאפשר לראות את "התמונה הגדולה" – כך מזהים שינוי אמיתי במצב המערכת.

3 אירוע שינוי במצב

EARLY BEARING (LUBRICATION) DEGRADATION

בלאי מוקדם של מיסב / הידרדרות במערכת השימון



תיאור האירוע



הידרדרות מוקדמת במיסב או בסיסוך, האירוע מתבטא בעלייה מתונה בטמפרטורת המיסב, עלייה ברעידות ובירידה קלה בלחץ שמן, יחד עם עלייה בטמפרטורת שמן שמן הסיכה. כל השינויים קטנים ונמצאים בתוך גבולות SCADA התקינים.


שינויים מתואמים (עדינים)

- עלייה קלה בטמפרטורת המיסבים ↑
- עלייה ברעידות המיסב ↑
- ירידה קלה בלחץ שמן ↓
- עלייה בטמפרטורת שמן הסיכה ↑



כל המשתנים נשארים בתוך גבולות תקינים של SCADA

מנמות המשתנים לאורך הזמן



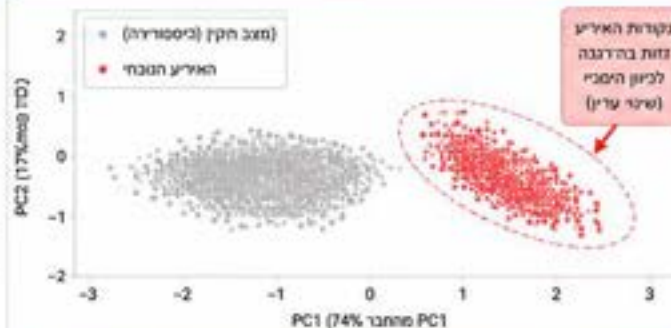
מנמות עדינית ומתואמות לאורך זמן – לא מזוהית ע"י SCADA

משתנים עיקריים בטבלת צפיפות מס' 3

משתנה	תיאור	כיוון שינוי באירוע
lube_oil_pressure_kPa	לחץ שמן הסיכה	ירידה קלה ↓
lube_oil_temp_C	טמפרטורת שמן הסיכה	עלייה קלה ↑
bearing_1_temp_C	טמפרטורת מיסב 1	עלייה קלה ↑
bearing_2_temp_C	טמפרטורת מיסב 2	עלייה קלה ↑
bearing_1_vibration_mm_s	רעידה מיסב 1	עלייה קלה ↑
bearing_2_vibration_mm_s	רעידה מיסב 2	עלייה קלה ↑

זהו באמצעות PCA (שני רכיבים ראשיים)

מבט דו פונדיו של המשתנים



התרחקות הדרגתית מאזור המצב התקין במרחב ה-PCA מעידה על התחלה של הידרדרות במערכת השימון / במיסב

מה מזהה מערכת EDS?



שילוב עדין של שינויים במספר משתנים במערכת השימון והמיסבים

- ✓ סטייה רב-משתנית עדינה
- ✓ אינה מזוהה ע"י SCADA
- ✓ מזוהה מוקדם ע"י EDS



גילוי מוקדם מאפשר תכנון התערבות, מניעת נזק להמיסב ומניעת עצירת יחידה




סיכום: שינויים קטנים ומתואמים במערכת הסיכה והמיסבים מלמדים על התחלת תהליך בלאי. EDS ממשלב משתנים רבים ומזהה את הסטייה המוקדמת לפני שהיא מובילה לתקלה משמעותית.

3 אירוע

– אירוע 3: תזוזה במצב תקין עקב הידרדרות במערכת השימון



תזוזת נקודות – אירוע 3



האירור מציג את PCA של מצב תקין (כחול) לעומת אירוע 3 – הידרדרות במערכת השימון (אדום).



מה רואים בגרף?


- נקודות התקינות (כחול) מרוכזות באזור אחד.
- נקודות אירוע 3 (אדום) נעות בצורה ברורה מהענן הכחול.
- יש שתי תת-קבוצות של נקודות אדומות – אמינות שונות של התקלה.



משמעות:

השידוש במרחב ה-PCA מצביע על שינוי במבנה הדפוסים של המערכת בגלל הידרדרות בשימון (לחץ שמן, ↓, טמפ' שמן, ↑, טמפ' מיסבים, ↑, רטט ↑).

כיוון השינוי



- PC1 (ציר אופקי): תזוזה חזקה ימינה –
- ↓ PC2 (ציר אנכי): תזוזה חזקה מטה –
- פיזור רחב יותר: שונות גבוהה יותר בין דפוסי ההידרדרות.



סיכום: תזוזה ברורה מהענן הכחול לשתי קבוצות אדומות מופרדות – סימן מובהק להתפתחות הידרדרות במערכת השימון.



הגורמים העיקריים לשינוי



משמעות עסקית

זיהוי מוקדם של הידרדרות השימון מאפשר מניעת נזק למיסבים, מניעת עצירות לא מתוכננות וחיסכון בעלויות.

4 אירוע שינוי במצב

FUEL-TO-POWER RESPONSE

מגמות בין דלק להספק – איזון הספק



תיאור האירוע



שינויים קטנים ומתואמים בזרימת הדלק מלווים בשינויים תואמים בהספק הגנרטור. המערכת פטעלת בטווח תקין ללא אזהרות. כל השינויים קטנים ונמצאים בתוך גבולות התקנים של SCADA.

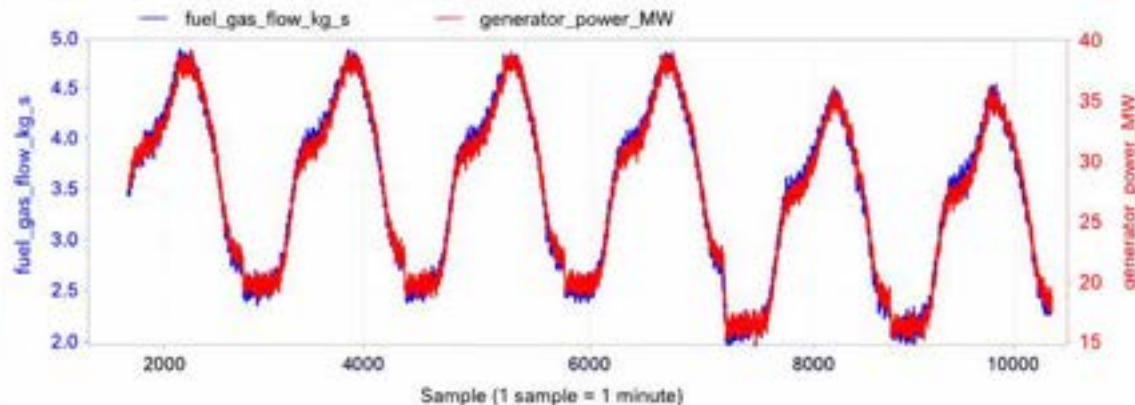
שינויים מתואמים (עדינים)

- זרימת דלק: תנודות קטנות סביב קו בסיס קבוע
- הספק גנרטור: התאמה כמעט ליניארית עם הדלק



כל המשתנים נשארים בתוך גבולות תקנים של SCADA

מגמות המשתנים לאורך הזמן




מגמות עדינות ומתואמות לאורך זמן – ללא מזהות ע"י SCADA

משתנים עיקריים בטבלת צפיפות מס' 4

משתנה	תיאור	כיוון שינוי באירוע
fuel_gas_flow_kg_s	ספיקת דלק	תנודות קטנות (בגוד ציוד בקריוב) ↔
generator_power_MW	הספק גנרטור	תנודות קטנות (בגוד ציוד בקריוב) ↔

זיהוי באמצעות PCA (שני רכיבים ראשיים)

מבט דו מימדי של המשתנים



נקודות האירוע קרובות למרכז האשכול התקין - PCA התנהגות צפויה של מערכת במצב תקין

מה מזהה מערכת EDS?



שילוב עדין ותואם בין ספיקת הדלק להספק הגנרטור

- ✓ סטייה רב-משתנית עדינה
- ✓ אינה מזהה ע"י SCADA
- ✓ מזהה מוקדם ע"י EDS



גילוי מוקדם מאפשר: אימות רצינות המערכת ומניעת בעיות עתידיות



סיכום: האירוע מציג תגובה תקינה של המערכת – שינויים קטנים ומתואמים בין ספיקת הדלק להספק. מערכת EDS מאששת את התנהגות המערכת ומספקת ביטחון תפעולי.



אירוע 4: תזוזת מצב תקין במרחב PCA – ללא הסטה משמעותית

4 אירוע

תגובת דלק להספק – איזון הספק



האירור מציג את מצב המערכת במרחב PCA בהשוואה בין מצב תקין (כחול) למצב במהלך אירוע 4 (אדום).

מה רואים בגרף?




- ✓ הנקודות האדומות (אירוע 4) חופפות כמעט לחלוטין את ענן הנקודות הכחול (מצב תקין).
- ✓ אין הסטה של מרכז הענן.
- ✓ אין שינוי בכיוון הפיזור – הגידול דומה.
- ✓ מרכזי הכובד (X) חופפים במרכז המרחב.



משמעות:


המערכת פועלת בתוך גבולות תקינות. לא מזוהה סטייה במבנה הדינמי של המשתנים. תגובת הדלק וההספק מתואמות כרגיל.



כיוון השינויים (PCs)

PC1 (ציר אופק): תנודות מהירות / הספק	↔
PC2 (ציר אנכי): דינמיקת בעירה / סמפרטורה	↕
PC3 (ציר עומק): תנודות משניות במערכת	

תזוזת נקודות במצב PCA – אירוע 4



נקודות אירוע 4 נמצאות בכל התחום של הענן התקין – ללא תזוזה משמעותית. המערכת פועלת בגבולות התקינות, ללא צורך בהתערבות.

מדדי לאירוע PCA 4



מרכז הענן אינו משתנה (אין הסטה)



כיוון הפיזור דומה למצב תקין (אין שינוי)



פיזור הנקודות בטווח הרגיל (אין חריגות)

מה זה אומר על המערכת?

מערכת תקינה התגובה הכוללת בגבולות הנורמה



ההספק מתואם המונע פועל בהתאמה לשינויים



בעירה יציבה אין שינוי בדינמיקת הבעירה



סיכום: אירוע 4 אינו מציין סטייה במצב הדינמי של המערכת. כל המשתנים נשארים בתוך תחום התקין של SCADA.



1. מקורות נתונים

Modbus TCP/IP CSV Files מסדי נתונים היסטוריים חיישנים ומערכות SCADA

קליטת נתונים בזמן אמת או היסטורי

2. מודל גמיש

ניהול גרסאות מודל
למידה חוזרת אוטומטית
ניהול פרמטרים

הגדרת משתנים
הגדרת Detectors
הגדרת Rules

בניית ותחזוקת מודל מותאם לתהליך שלכם

4. ניתוח ותצוגה מתקדמים

Log Viewer דיווח ולידציה אירועים והתראות סבלאות צפיפות Heat Maps קרלציה גרפי גרמנות גרפי מגמות

תצוגה אינטואיטיבית להבנה וקבלת החלטות מהירה

3. יכולות זיהוי מתקדמות

- זיהוי קפיצות פתאומיות
- זיהוי ערכים קבועים
- זיהוי תקלות תקשורת
- זיהוי שינוי ברעש
- זיהוי חריגות מחיישן בודד
- זיהוי חריגות רב-משתניות
- לימוד גבולות סטטיסטיים אוטומטי
- לימוד תחומי פעולה חקונים (Good State)
- זיהוי צירופים חריגים (Density Tables)
- זיהוי שינוי מגמה (Trend)
- זיהוי הידרדרות הדרגתית

גילוי מוקדם של תקלות לפני השפעה על התהליך



5. אינטגרציה ויצוא מידע

SCADA EMS PLC Historian MSMQ Servers Cloud

שילוב חלק עם מערכות וממשקים קיימים

6. פלטפורמות נתמכות

Raspberry Pi Radxa Banana Pi BeagleY AI Intel NUC Windows Linux Docker Cloud VM

התקנה גמישה על מגוון רחב של פלטפורמות – מקצה לקצה

- למה MicroEDS?
- זמן תגובה מהיר
- ללא צורך בענן
- צריכת משאבים נמוכה
- למידה בלתי מונחית (Unsupervised)
- אמין ויציב 24/7
- זיהוי מוקדם של תקלות
- הפחתת False Alarms
- התקנה על SBC זול ופשוט



שאלות לסיכום ההרצאה

נשמח לשאלות, התייחסויות והערות



1 מהי מטרת מערכת MicroEDS?

כיצד היא מסייעת לזיהוי מוקדם של אירועים חריגים בתעשייה?

2

כיצד MicroEDS מזהה אירועים חריגים?

אילו סוגי דטקטורים ואלגוריתמים המערכת מפעילה?



3 אילו מקורות נתונים ניתן לחבר למערכת?

איך מתבצע יבוא הנתונים למערכת?

4

כיצד בונים ומנהלים מודל ב-MicroEDS?

מהם המרכיבים המרכזיים במודל (משתנים, דטקטורים, חוקים)?



5 מהם כלי הניתוח והתצוגה הזמינים במערכת?

כיצד הם מסייעים להבנת מצב התהליך?

6

איך MicroEDS משתלב במערכות ארגוניות?

עם אילו מערכות ניתן לבצע אינטגרציה (SCADA, EMS, PLC, Cloud וכו')?



7 מהם היתרונות של הפעלה על SBC?

כיצד זה משפיע על עלות, ביצועים וזמן תגובה?

8

כיצד MicroEDS תורם לשיפור תפעולי?

מהם הערכים המרכזיים שהוא מביא לארגון ולתהליך התעשייתי?



אנחנו כאן כדי לענות – שאלו אותנו!



MicroEDS
Events Detection System