

זיהוי אנומליות במערכות מורכבות

• "כולם משוגעים חוץ ממני"



INCOSEIL 2024

יוני 2024, הרצליה

רענן נורדון

אלביט – חטיבת כלי טייס / מל"ט

"אנומליות"?



- הגדרה בעייתית - על דרך השלילה

- הבנה אינטואיטיבית

- "I can't define it, but I know it when I see it"

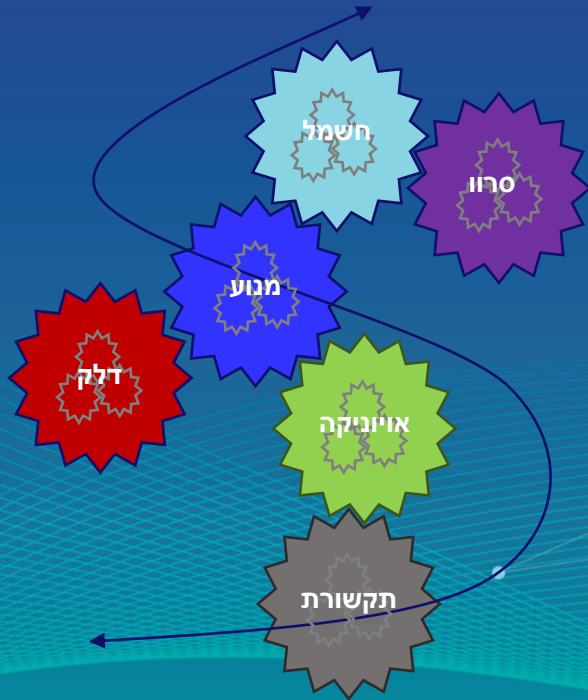
- נקודת המבט של "אלביט מל"ט": System of systems, ניטור בריאות מטוס




אנומליות במערכות מורכבות?

- גישה נפוצה: להתמקד במספר מוקדי כשל עיקריים או קריטיים.
- מה מיוחד במערכות מורכבות?
- במערכות מורכבות יש **מספר גדול של מודי כשל – רובם המוחלט בהסתברות נמוכה.**
- **משמע:**

- ההסתברות הכוללת משמעותית
- תקלות אשר לא חוזרות על עצמן
- לא מעשי לתפור פתרון ניטור לכל כשל אפשרי
- מרחב פרמטרים גדול ← הרבה אנומליות ולא כולן מעניינות.



- הנורמה - מצב מערכת צפוי/מוכר במרחב רב מימדי
- המצב **האמיתי** לרוב לא ידוע:
- יש להסיק את המצב מהפרמטרים עצמם
- הפרמטרים הנמדדים "רועשים"
- בעיית אסינכרוניות דגימות, והשהייה



- כדי להגדיר סטייה מנורמליות נדרש:
- קביעת ספים – ספים על מה?
- דרישת הסתברות התראות שווא (Pfa) – מהי התראת שווא?
- דרישת הסתברות גילוי (Pd) – גילוי של מה?

אנומליות ייחוס – Relation Anomaly

- הקשר בין הפרמטרים הנמדדים אינו תואם ליחס הנורמלי ביניהם (עלול להיות מורכב) – המספרים "לא מסתדרים".
- פחות רגיש לתפעול לא רגיל של המערכת.
- רגיש לתקלות טכנית המשנות את תפקוד המערכת.



יחס אנומלי בין מהירות סיבוב הגלגל להתקדמות המכונית

אנומליות מצב – State Anomaly

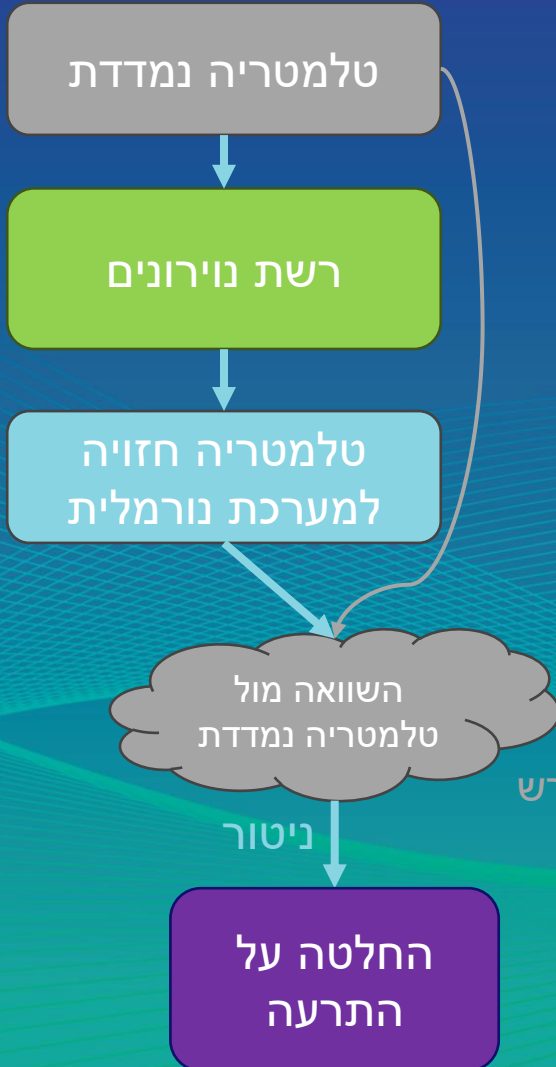
- "המערכת" נמצאת במצב "חריג" - שלא נצפה קודם
- ה"מצב" לא תמיד ידוע בוודאות (אין ground truth)
- דוגמה פשוטה: המטוס נמצא בגובה 20 kft כאשר בבסיס הנתונים אין דוגמאות מעל 16 kft.
- אפשרויות:
 - "אנומליה" הקשורה לתפעול המערכת – לא תקלה טכנית.
 - תקלה הגורמת להערכת מצב שגוייה.



מצב לא רגיל

גישות לפתרון בעזרת DL –

un-supervised / self-supervised



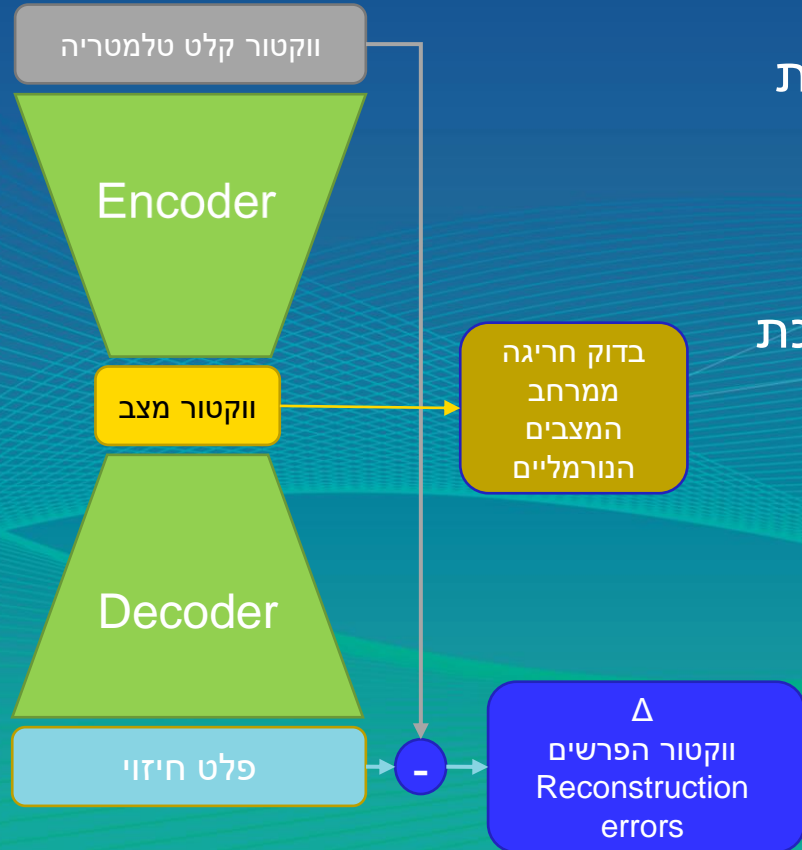
העקרון:

- אימון הרשת לחזות ערכי טלמטריה ו/או מצב המערכת עבור "נורמליות"
- **האימון מבוצע על דוגמאות "תקינות"** ככל האפשר, ללא אנומליות (לפחות לא מהסוג שנרצה התראה עליהן)
- בסיס הנתונים לאימון יגדיר את הנורמליות.
- בניטור (inference) – אנומליות יתבטאו בסטיית המדידים מערכי הטלמטריה החזויים ו/או ווקטור "מצב" החורג ממרחב המצבים הנורמליים
- **מדוע לא Supervised?**
- בעיתיות ה-Ground Truth (דוגמאות מתייגות):
- תיוג של דוגמאות מלמד את ה-AI לזהות אנומליות שהמתייגים חשבו עליהן.
- האנומליות שלנו מאופיינות כנדירות ומגוונות
- קשה לסמלץ תקלות אמיתיות.

גישות לפתרון בעזרת DL –

Auto-Encoder self-supervised

אימון על
Data "תקין"



- חישוב ערך "נורמלי" חזוי לפרמטרי הקלט* בעזרת עצמים
 - Encoder דוחס את אינפורמצית הקלט לווקטור נסתר המייצג **שערוך של מצב המערכת האמיתי**
 - Decoder בהנתן מצב המערכת, משערך מה מדידי הטלמטריה אמורים להראות הפרדה בין סוגי האנומליות:
 - אנומליות מצב – עלפי חריגת ווקטור המצב ממרחב המצבים ה"נורמלי"
 - אנומליות ייחוס – מתבטאות כ-reconstruction errors
 - גישה "הוליסטית" – הכל מטופל ביחד, צורך מינימלי בלבד ב"הבנה" של המערכת
- * ניתן לכלול פרמטרי קלט שאינם מנוטרים (לא בפלט)

איפה האנומליות?

- אימנו רק על Data "נורמלי" – בכלל לא הגדרנו או הסברנו מה זו אנומליה...
- אנו "בונים" על כך שאנומליות יחסית יתבטאו בסטייה של הערך החזוי מהערך המדוד

סטייה בכמה?

- שלב שני של "לימוד":

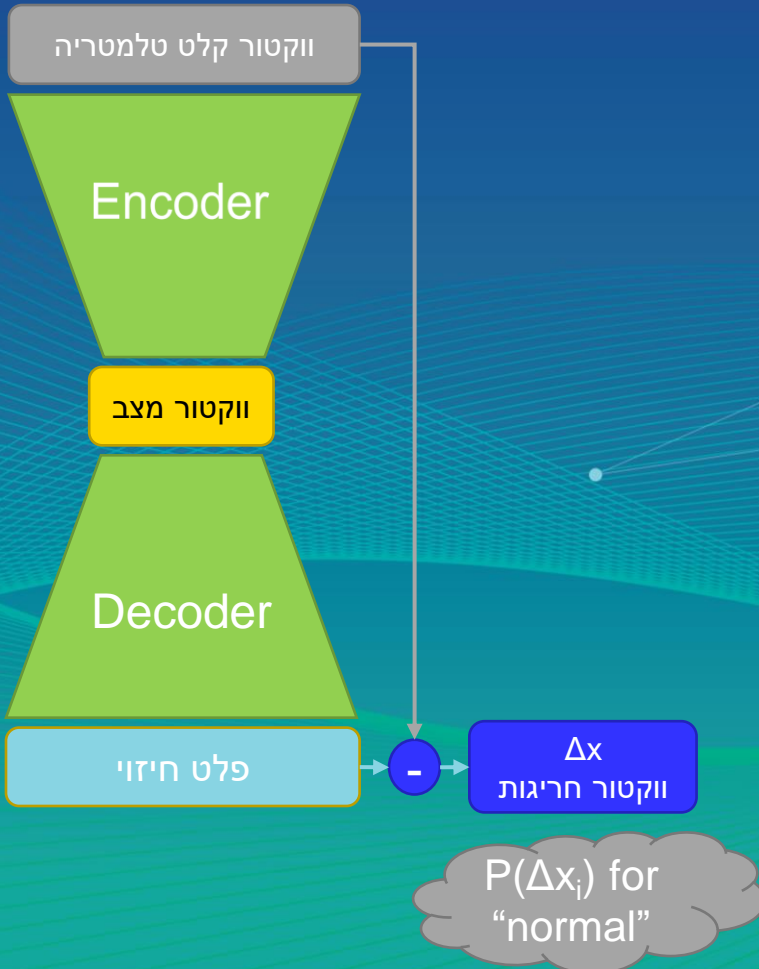
- תחום המצבים הנורמלי
- דיוק החיזוי ה"נורמלי" של הרשת

הדרישה מובילה: הסתברות/קצב התראות שווא (false-positives):

- מוגדר היטב – כל אנומליה הנמצאת בסט האימון/בדיקה היא false-positive
- נקבע את ספי ההתרעה כך שנעמוד בדרישת התראות השווא

תוצאתי: הסתברות גילוי לאנומליות

- באופן כללי - לא מוגדר היטב
- מוגדר רק על סט של דוגמאות – selection bias, ועלול להיות שונה במבצעי

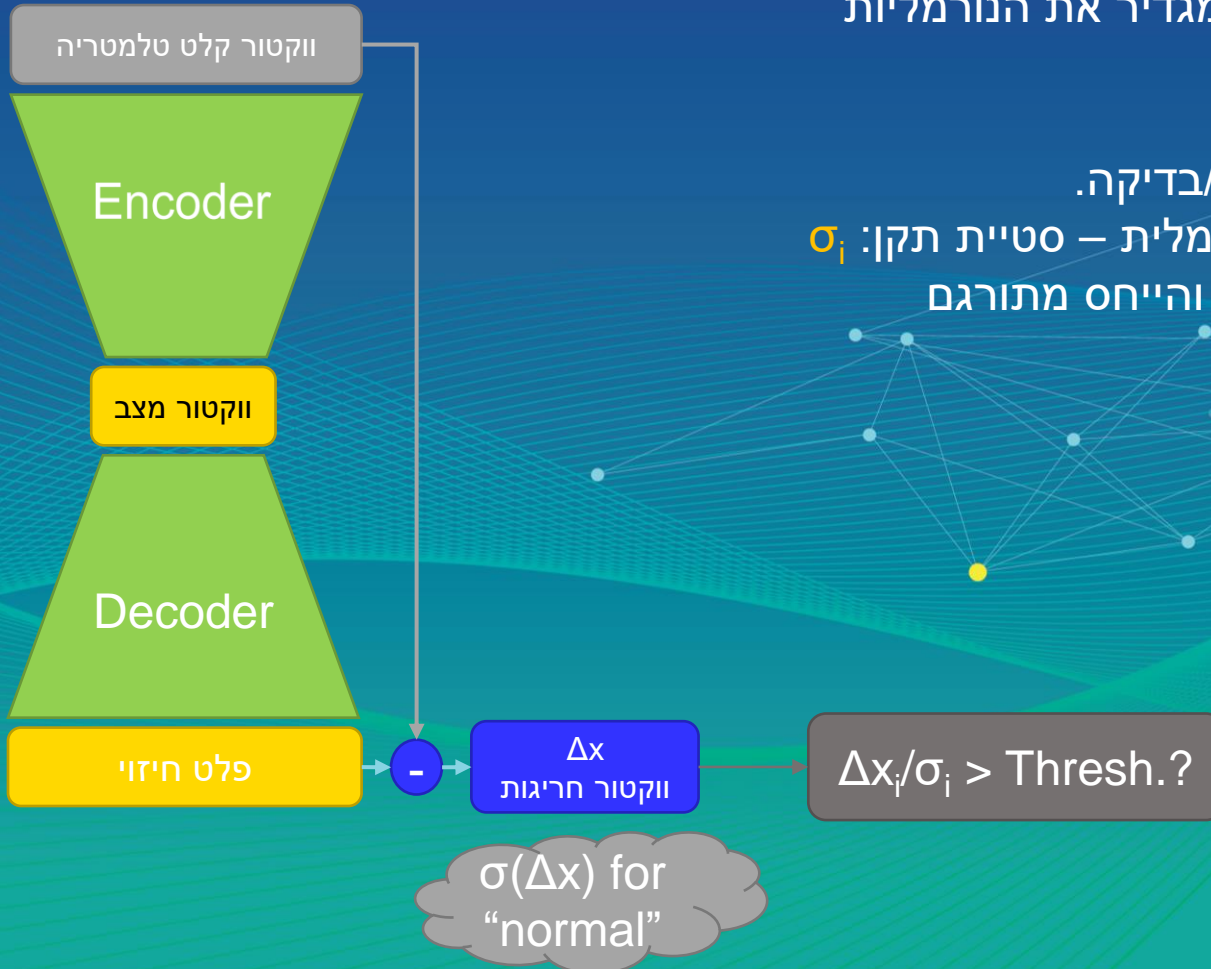


הגדרת האנומליות על דרך השלילה

- אנומליות מוגדרת ע"י הסתברות אי ההשתייכות שלהן לסט האימון.
- נקבע סף אנומליות אשר יקיים את דרישת הסתברות False-Positive מקסימלית
- במילים אחרות: מנסים לפסול את השתייכות ה-Datum לסט המגדיר את הנורמליות

• דוגמה הכי פשוטה (וקצת נאיבית):

- "נמדוד" את התפלגות שגיאת החיזוי Δx של Data האימון/בדיקה.
- נניח שההתפלגות עבור פרמטר x_i מקורבת להתפלגות נורמלית – סטיית תקן: σ_i
- בניטור – נשווה את Prediction Error Δx_i לסטיית התקן, והייחס מתורגם להסתברות $P_i = \text{Erfc}(\Delta x_i / \sigma_i)$
- נקבע את סף האנומליה בהתאם.

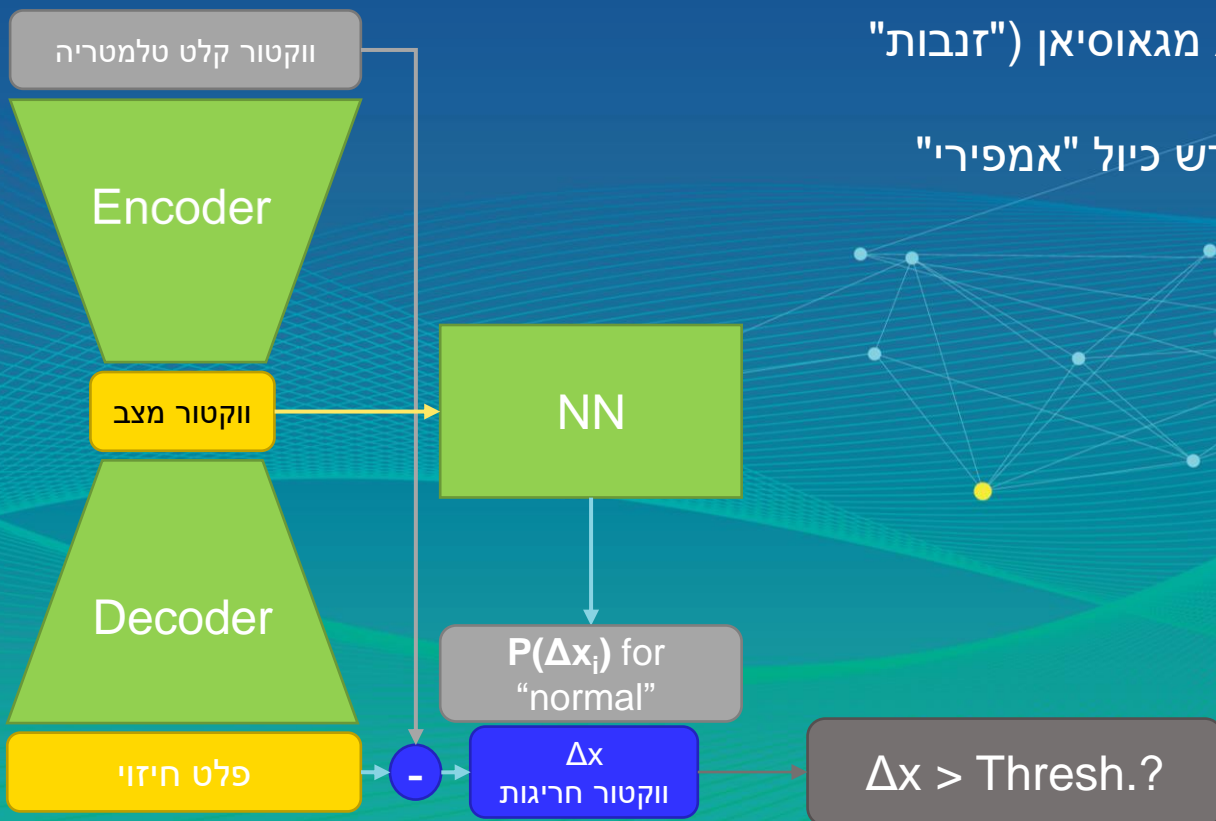


לימוד דיוקי החיזוי וספי האנומליה

- במערכת מאוד דינאמית דיוקי החיזוי אינם קבועים ותלויים במצב המערכת
- ניתן ללמוד את דיוקי החיזוי כתלות במצב.

• התפלגויות לא גאוסיאניות:

- עבור הסתברויות נמוכות ההתפלגויות של Δx נוטות לחרוג מגאוסיאן ("זנבות" ארוכים)
- אם דורשים הסתברויות False-Positive מאוד נדרש כיול "אמפירי" להסתברות $\Delta x/\sigma$



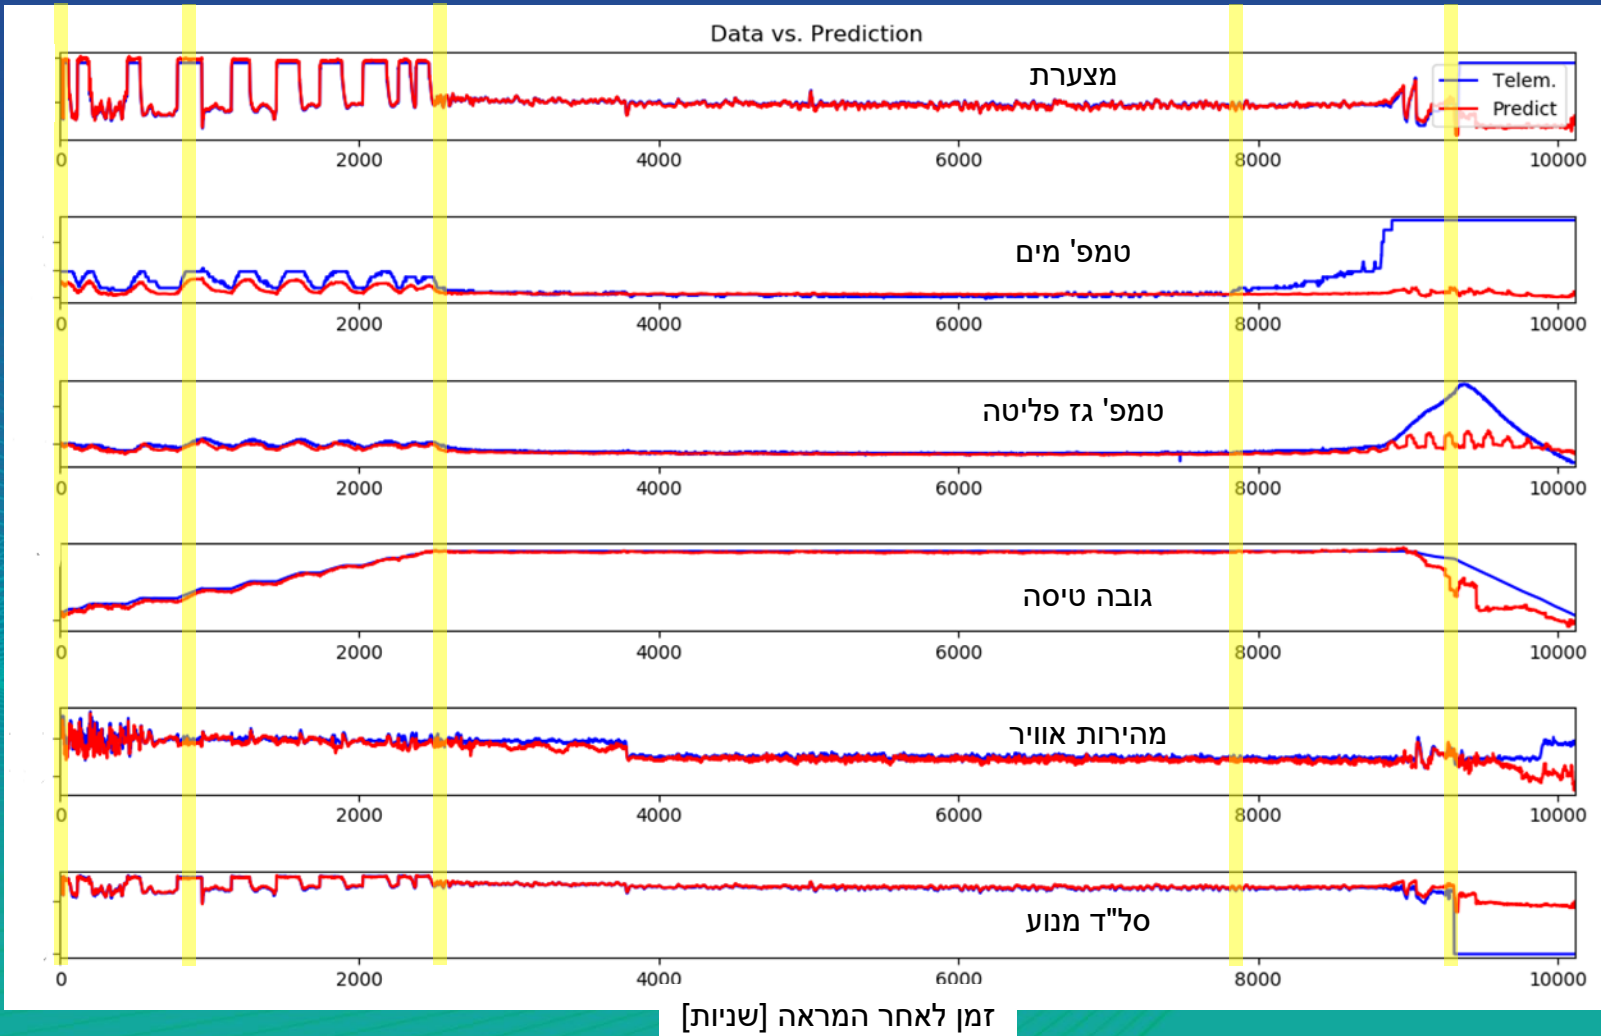
Takeoff
& Climb

t=960

Level
Cruise

Critical
Failure

Engine
Cut



- ניטור טלמטריה של מטוס עם תקלת מניפת קירור

- מוצג: 6 פרמטרים מתוך כ-50 מנוטרים

- **אדום** – חיזוי הרשת

- **כחול** – טלמטריה

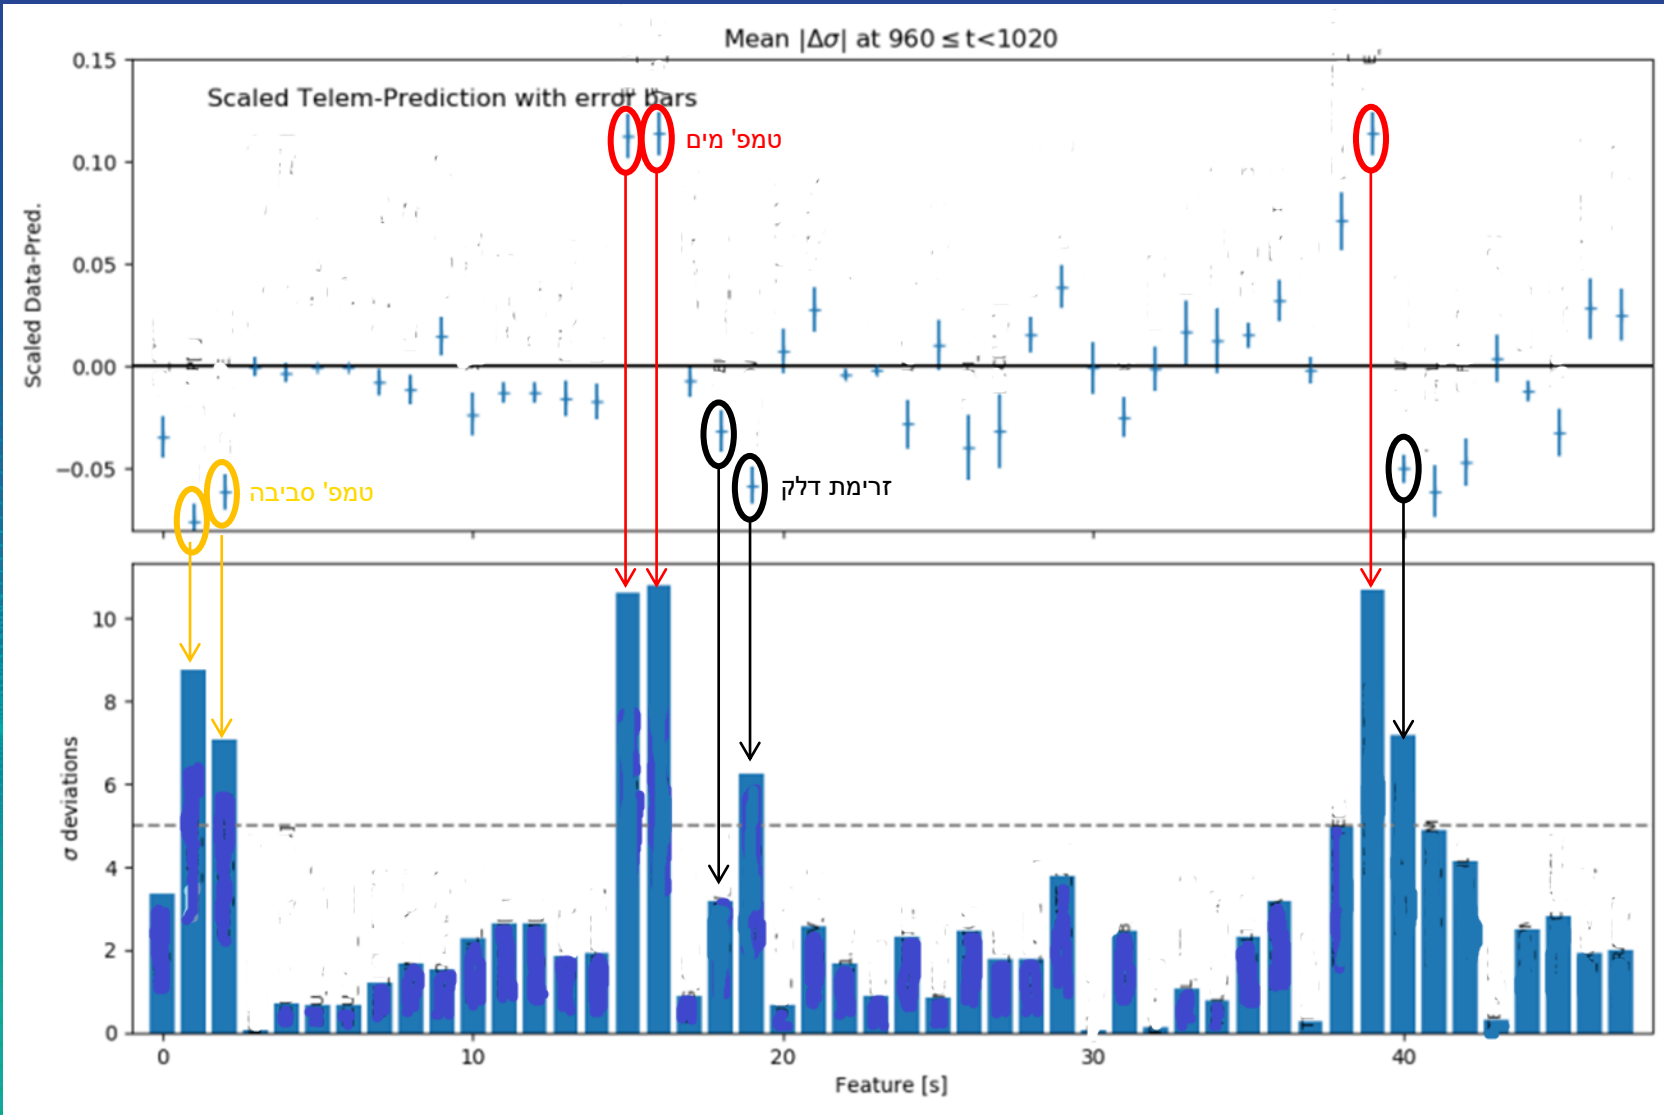
- שבר קריטי לאחר קצת מעל שעתיים של טיסה (t~8000)

- חריגות טמפ' מים (רדיאטור) מהחזוי מיד לאחר המראה ובזמן הטיפוס

- טמפ' מים לא חריגות אבסולוטית!

- אחרת היו מחזירים את המטוס מייד

- הטמפ' נורמליות בזמן שיוט – קירור מספק גם עם מניפה פגומה



- ניטור החריגות כ-15 דקות לאחר המראה
 - **טמפ' המים** חורגת מעלה (גבוהה)
 - **טמפ' הסביבה** חורגת מטה (נמוכה)
 - **זרימת הדלק** חורגת מטה (נמוכה)
 - תרגום:
- "טמפ' המים גבוהה מדי ביחס לטמפ' הסביבה וקצב שריפת הדלק"



Key Takeaways / Key Points

- במערכות מורכבות מספר רב של מודי כשל בהסתברויות נמוכות.
- הבדל קונספטואלי בין קטגוריות של אנומליות
 - State Anomalies – אנומליה של המערכת, לרוב קשור ל- "תפעול"
 - Relation Anomalies – אנומליה במערכת, לרוב בשל שינוי במערכת (תקלות)
- הגדרת האנומליה ע"י אי השתייכותה למרחב המצבים/הייחסים בנורמליות (ה-DATA) – בהסתברות סף מסויימת
- הדרישה המובילה – הסתברות התראות השווא (False-Positives)

