人工知能学会 インタラクティブ
情報アクセスと可視化マイニング研究会(第29回)
SIG-AM-29-04

灯油タンク内の液面高の計測における レーザセンサデバイスの故障検知

Failure detection of a laser sensor device in the measurement of liquid level height in a kerosene tank

三浦颯太[1*]　横山想一郎[2]　山下倫央[2]　川村秀憲[2]　多田満朗[3]
Sota Miura[1], Soichiro Yokoyama[2], Tomohisa Yamashita[2], Hidenori Kawamura[2], and Mitsuo Tada[3]

[1] 北海道大学 大学院情報科学院
[1] Graduate School of Information Science and Technology, Hokkaido University
[2] 北海道大学 大学院情報科学研究院
[2] Faculty of Information Science and Technology, Hokkaido University
[3] ゼロスペック株式会社
[3] ZeroSpec Inc.

Abstract: In recent years, IoT laser sensors have been developed and installed on household kerosene tanks to measure the amount of remaining kerosene in order to improve the efficiency of kerosene delivery. For efficient operation of the laser sensor, this study proposes a method for estimating the refueling time of kerosene tanks using laser sensor measurements, a method for detecting failures of the laser sensor itself, and a method for detecting abnormal fluctuations in the measured values. Experiments using actual laser sensor measurements confirm that the three proposed methods are effective and accurate in practical use.

1　はじめに

1.1　研究背景

灯油配送は主に寒冷地で行われている業務である．寒冷地の住宅には冬場の暖房やロードヒーティングに使用する灯油を貯蔵するタンクが設置されており，定期的に配送を受けることで燃料を切らさずに暖房などを使用し続けることができる．通常，灯油配送のタイミングや配送量は配送業者側が灯油タンクを空にしないように決めていく．

灯油配送業を取り巻く問題としては，近年人手不足によって，一人当たりの労働負荷が上昇していることが挙げられている．この労働負荷，および，労働時間の増加がさらなる呼び水となり，離職率の増加や，灯油配送遅れによる灯油切れが生じてしまう危険性がある．灯油切れにより，冬場に暖房が使用できず室温が下がることで，居住者が生活を行う上での支障を来たす可能性がある．また，ロードヒーティングが行えなくなることで道路が凍結するため，発生する事故の増加も考えられる．さらに，一度灯油を切らしてしまうと，灯油用のホース内に空気が詰まってしまい，それを取り除くために 30 分程度の時間を要するため，灯油を切らさないための配送計画の作成が重要となる [1]．配送計画を作成するうえで，タンク内の灯油の在庫管理が重要である．従来は顧客の過去の消費傾向からタンク内の残量が無くならないように配送頻度を決定し周期的に配送していた．また，機械学習を使い過去の消費傾向を学習して灯油タンクの現在の残量推定を行う研究も行われているが，新規の顧客や，消費傾向が変化する顧客に対する残量推定は難しい [2]．そこで近年，リアルタイムで灯油残量の計測が可能な IoT レーザセンサの開発及び設置が進んでいる．しかし，センサは各家庭の灯油タンクに設置しなければならないため，コストの制約から安価なものを使用しなければならない．また，通常屋外にある灯油タンクにセンサを設置するため，夏は炎天下，冬は極寒に晒されるなど計測環境が悪い．このような要因からセンサが故障したり，異常値を計測してしまうなどの事例が発生するため，計測値を配送計画に使用するには信頼度が低

*連絡先：北海道大学 大学院情報科学院
〒 060-0814 北海道札幌市北区北 14 条西 9 丁目
E-mail: miurasota@ist.hokudai.ac.jp

いのが現状である．

1.2 研究目的

本論文では，灯油配送計画のための信頼性の高い残量把握における，故障センサへの適切な対応を支援するシステムを開発することを目的し，システム内で使用する異常検知手法を提案する．具体的には，センサの計測値と給油時刻データから計算可能な特徴量を用いた，分類器ベースの異常検知手法の検証を行う．特徴量には，一定期間内で給油時刻推定を行った予測給油時刻と，実際の給油時刻から計算できる F1 スコアを含める．したがって，まず初めに計測値から給油時刻を推定する手法を提案し，検証を行う．ここで，正常な計測値から正しく給油時刻を推定できることの確認を行い，その後給油時刻推定の F1 スコアとその他の計算可能な特徴量を用いた異常検知手法の検証を行う．また，発生期間の長さが異なる異常をそれぞれ検知するために，異常検知手法の検証は扱う時系列の長さを変えて，二種類の枠組みの検証を行う．一つ目は，給油の消費が多い冬季を含む 7ヵ月間の計測値を一つの時系列として扱い，正常か異常かの分類を行う．以下，一つ目の枠組みを異常変動検知（1 シーズン）とする．二つ目は，計測値を給油時刻から次の給油時刻までで区切った期間を一つの時系列として扱い，正常か異常かの分類を行う．以下，二つ目の枠組みを異常変動検知（給油間期間）とする．

図 1 に考案したシステムの全体図を示す．異常変動検知（１シーズン）はセンサが故障しているかの判定に使用し，異常変動検知（給油間期間）は，より短い期間でセンサが不調であるかの判定に使用する．異常の判定にこの二つの枠組みを使用する理由は，発生期間が短い異常と長い異常で別々の対応をするためである．発生期間が長い異常はセンサが故障していると判断し交換をしなければならない．発生期間が短い異常は，レーザの射出口を清掃することにより再び正常な計測が可能になる場合があるため，射出口を清掃し様子を見る必要がある．

1.3 本稿の構成

以下に本論文の構成を示す．第 2 章では時系列データを扱った異常検知に関連した研究の解説を行う．第 3 章では，本論文で扱うレーザセンサデバイスの概要と，扱うデータの性質についての解説を行い，第 4 章では本論文で提案する給油時刻推定と異常変動検知（1 シーズン），異常変動検知（給油間期間）についての解説を行う．第 5 章の 5.1 節で提案手法の有効性を検証するための実験についての解説を行い，5.2 節で実験の結果及び考察を行う．最後に，第 6 章にて本論文のまとめを述べる．

2 関連研究

実世界の重要な問題として時系列異常検知は広く研究されており，それらの多くは教師ありと教師なしに分類される．教師あり時系列異常検知は時系列分類問題（TSC: Time Series Classification）の一つとして研究されており，TSC の中で分類クラスが異常と正常の二値分類である問題を異常検知としている．

TSC の先行研究としては，Maletzke らの研究 [3] が存在する．この研究では 5 つの医療時系列データから，平均や分散などの統計的な特徴量やエントロピー，フラクタル次元などの複雑さを表す特徴量を抽出し決定木モデルを用いて，てんかん患者の推定を行った．さらに，井上らの研究 [4] では家庭の電力時系列から統計的な特徴量を抽出し，単純ベイズ分類器で個別家電機器の動作状態の推定を行った．これらの研究では，時系列から固定長の特徴量を計算し，分類器で教師あり学習をしている．また，茂木らの研究 [5] では，振動センサの計測値から流量実験設備に組み付けられた調節弁の異常検知を行っている．この研究では計測値から得られた時系列をそのまま入力として，CNN-LSTM を用いて教師あり学習をしている．

教師なし異常検知は異常の判定基準により，密度推定法 [6, 7]，クラスタリングベース [8, 9]，再構成ベース [10, 11]，自己回帰ベース [12] などに分類できる．また，近年様々な問題で力を発揮しているトランスフォーマーを用いた異常検知手法も Jiehui ら [13] によって提案されており，時系列異常検知ベンチマークにおいて最先端の結果を出している．

教師なし異常検知が多く研究されている背景として，実世界の問題では異常データが正常データに比べて極端に少なく教師あり学習が困難であることが挙げられる．本論文で扱う問題では異常データが十分あるため，教師なし学習よりも有効であると考えられる教師あり学習を採用する．

3 レーザーセンサデバイス

本論文で扱うレーザセンサデバイスは灯油タンクの蓋に設置され，タイムオブフライト方式で油面との距離を計測する．タイムオブフライト方式とは，光を対象に向けて発射し，照射時間と受光時間の時間差から距離を計測する方式である [14]．計測した距離は LPWA ネットワークによりクラウドに保存されるため，インターネットが繋がる環境であればどこでも灯油タンク内の残量を把握することができるが，1.1 節で述べた通

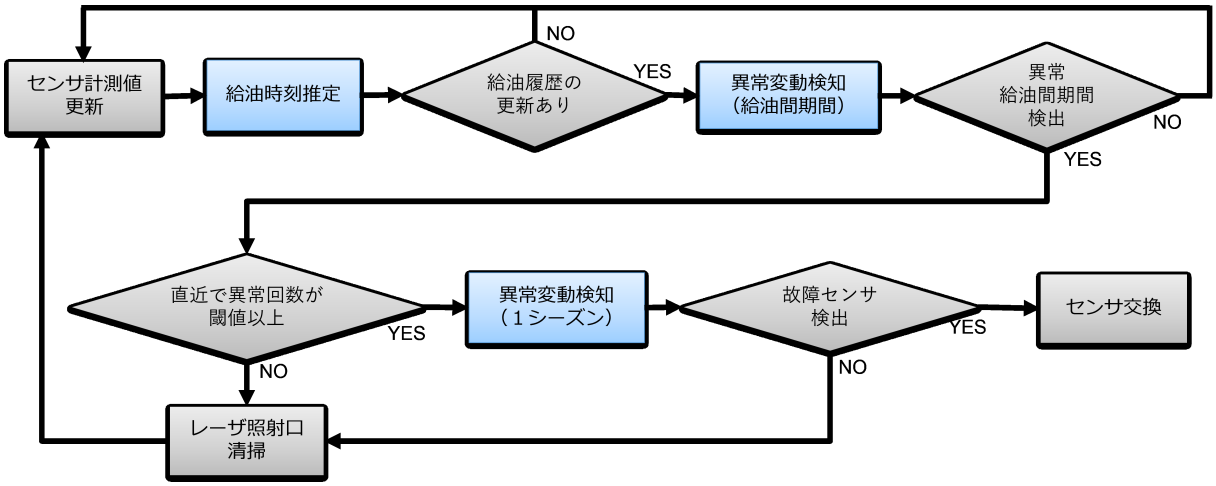

図 1: 異常センサ検出システム.

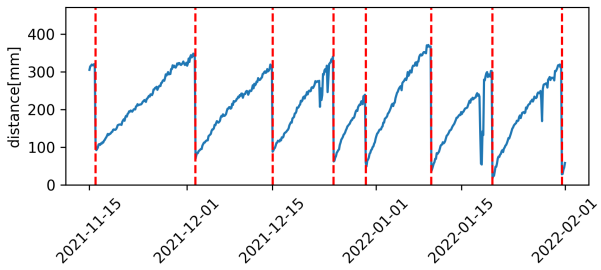

図 2: センサ計測値.

り，コストの面から高精度なセンサは使うことが出来ないため，ある程度の誤差は想定している．また，消費電力低減のために距離計測は 3 時間毎に行われるため，センサから得られるデータは 3 時間間隔の時系列データである．

本論文で扱うデータの例として，あるセンサにおける計測値の時系列および給油履歴を図 2 に示す．図に示す期間は 2021 年 11 月 15 日から 2022 年 2 月 1 日までとなっており，縦軸が油面との距離，横軸が時間である．赤い点線はタンクに給油した時刻を表している．図 2 より，センサ計測値は時間経過とともに徐々に油面との距離が大きくなり，給油が行われると油面との距離が急激に小さくなる．次に，センサにみられる異常の例を図 3 に示す．図 3(a) はある一定期間に計測値が変動していない．図 3(b) は連続でスパイクが立っている．図 3(c) は計測値が減少傾向にある．いずれも図 2 とは異なる挙動を示している．

また，提案する手法には，センサ計測値の他にもタンクへ給油した時刻と量のデータが必要であるが，本論文ではそのような給油履歴が取得可能な状況を想定して実験を行う．

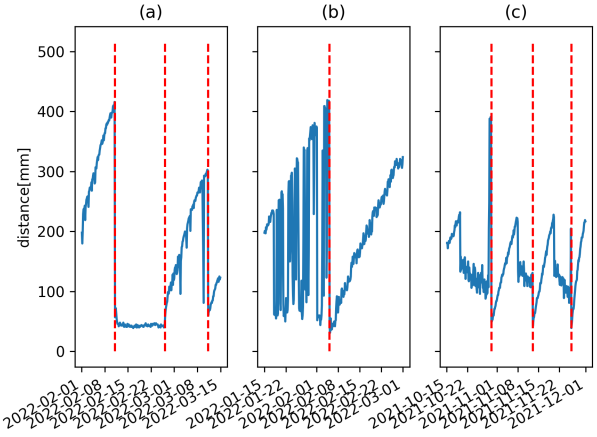

図 3: 異常センサ例.

4 提案手法

本章では，提案する給油時刻推定と異常変動検知手法について述べる．使用するデータはセンサ計測値と，各灯油タンクへの給油時刻と給油量が記録された給油履歴である．計測値 $\boldsymbol{X}$ は時刻 t の計測値を $x_t \in \mathbb{R}$ として，集合 $\{x_1, x_2, ..., x_N\}$ で表す．また，給油時刻 $\boldsymbol{T}_s$ は時刻の集合 $\{t_{s,1}, t_{s,2}, ..., t_{s,K}\}$ で示され，$t_{s,k} \in \mathbb{N}$ は k 回目の給油の給油時刻を表している．

4.1 給油時刻推定

センサ計測値から給油時刻を推定するために，給油時刻付近での計測値の挙動について考える．第 3 章で述べた通り，センサ計測値は時間経過とともに徐々に油面との距離が大きくなり，給油が行われると油面との距離が急激に小さくなる．つまり、給油時刻を推定するには前ステップとの差分が大きい箇所に注目すれば

良い．しかし，図 2 の 2022 年 1 月 15 日付近にみられるように，計測値にはスパイクが立つことがしばしばある．このようなスパイクも前ステップとの差分が大きくなるため，給油時刻を推定するためには，差分だけではなくその後の時系列も考慮しなければならない．

このことを踏まえて，以下の手順で給油時刻推定を行う．

1. 隣り合う 2 点間の差分の絶対値を計算し，差分が閾値以上である時刻を給油時刻候補として挙げる．
2. 過去の給油時刻から，給油時刻直後数ステップの計測値をサンプリングして平均と分散を求める．
3. ホテリング理論により，求めた平均と分散から給油時刻候補直後数ステップの計測値に対する異常度を計算し，異常度が閾値以下である給油時刻候補を給油時刻と推定する．

ここでは，ある灯油タンクの l 回目までの給油時刻が分かっていて，それ以降の給油時刻を推定する問題を考える．まず，以下の式で前ステップとの計測値の差分を計算する．

$$\Delta x_t = x_t - x_{t-1} \tag{1}$$

ここで Δx_t は絶対値ではなく，相対値で計算する．これは，給油時刻では計測値が負の方向に大きく変化することが分かっているためである．Δx_t が負の方向に大きい時刻の集合を給油時刻候補 $\boldsymbol{T}_{sc} = \{t_{sc,k'}\}_{k'=1}^{K'}$ とする．また，このときの閾値を $\gamma_{\Delta x_t}$ とする．次に過去の計測値と給油履歴から，給油直後 n ステップの計測値をサンプリングして，平均値 μ と分散 σ^2 を以下の式で求める．

$$\mu = \frac{1}{nl}\sum_{k=1}^{l}\sum_{t=t_{s,k}}^{t_{s,k}+n-1} x_t \tag{2}$$

$$\sigma^2 = \frac{1}{nl}\sum_{k=1}^{l}\sum_{t=t_{s,k}}^{t_{s,k}+n-1} (x_t - \mu)^2 \tag{3}$$

n は十分小さく正規分布に従う測定誤差を除き計測値は変動しないため，サンプリングした計測値は正規分布に従うと仮定できる．したがってホテリング理論より，給油直後の計測値の異常度 a が計算できる．ここで，給油時刻推定には $\boldsymbol{T}_{sc}$ 直後の数ステップを考慮する必要があるため，異常度 a の計算には $\boldsymbol{T}_{sc}$ 直後の n ステップの平均を用いる．k' 番目の給油時刻候補の異常度 $a_{k'}$ は以下の式で計算できる．

$$a_{k'} = \frac{(\bar{x}_{t_{sc,k'}} - \mu)^2}{\sigma^2} \tag{4}$$

$$\bar{x}_{t_{sc,k'}} = \frac{1}{n}\sum_{t=t_{sc,k'}}^{t_{sc,k'}+n-1} x_t \tag{5}$$

(4) 式で求めた異常度は正規分布からの距離を表しており，異常度が大きいほど過去の給油時刻直後の計測値の傾向から外れていることが分かる．したがって，異常度 $a_{k'}$ が小さい給油時刻候補 $t_{sc,k'}$ を給油時刻として推定し，このときの閾値を γ_a とする．また，(4) 式で計算される異常度はカイ二乗分布に従うため，閾値 γ_a は確率を表すパラメータ α により一意に決まる．

$$\alpha = 1 - \int_0^{\gamma_a} \chi^2(a|1,1)da \tag{6}$$

4.2 異常変動検知（1 シーズン）

提案手法では，図 3 のような計測値をとる異常センサを検知することを目的として，計測値と給油履歴から計算できる固定長の特徴量を抽出し，単純な分類器で教師あり学習を行う．教師ラベルは正常と異常の 2 種類で，7ヵ月間の時系列に対してアノテーションを行う．抽出する特徴量と計算式を以下に示す．

１回当たりの平均給油量：$\bar{V}$

$$\bar{V} = \frac{1}{K}\sum_{k=1}^{K} V_k \tag{7}$$

ここで，K は7ヵ月間で行われた給油回数，V_k は k 回目の給油の給油量を表している．

平均給油間隔：$\Delta\bar{t}_{s,k}$

$$\Delta\bar{t}_{s,k} = \frac{1}{K-1}\sum_{k=1}^{K-1}(t_{s,k+1} - t_{s,k}) \tag{8}$$

１ヶ月当たりの平均給油回数：$\bar{K}$

$$\bar{K} = \frac{240K}{N} \tag{9}$$

ここで，分母は時系列のステップ数，分子の 240 は1ヶ月当たりのステップ数を表している．異なる長さの時系列にも応用可能にするため，1ヶ月で正規化する．

給油時刻推定の F1 スコア

4.1 節で提案した給油時刻推定が正常センサに対して性能が良く，異常センサに対して性能が悪いと考えられるため，給油時刻推定で得られた F1 スコアを特徴量とする．まず，時系列に対して 4.1 節で提案した給油時刻推定を行う．次に，給油時刻推定を各ステップが給油時刻か給油時刻以外か

の二値分類問題として扱い，F1 スコアによって評価を行う．二値分類問題において，給油時刻以外を給油時刻とラベル付けされた場合の数を偽陽性（FP）と表す．偽陰性（FN）は，給油時刻が給油時刻以外であるとラベル付けされた数を表す．真陽性（TP）および真陰性（TN）は，給油時刻と給油時刻以外が正しく識別された数を表す．これらを用いて，精度，再現率，F1 スコアは以下のように評価される．

$$precision = \frac{TP}{TP + FP} \tag{10}$$

$$recall = \frac{TP}{TP + FN} \tag{11}$$

$$F1score = 2 \times \frac{precision \times recall}{precision + recall} \tag{12}$$

ノイズの強さ：d

計測値に対するノイズの強さを定量的に数値化するためにローパスフィルタを用いる．ローパスフィルタは，ノイズなどの特定の閾値よりも高い周波数信号を減衰させて遮断し、低域周波数のみを信号として通過させることができる．提案手法では，元の計測値 $\boldsymbol{X}$ とローパスフィルタ適用後の計測値 $\boldsymbol{X}_{lpf}$ との差分を時系列の長さで正規化した値をノイズの強さとして定義する．

$$d = \frac{1}{N} \sum_{t=1}^{N} |x_{lpf,t} - x_t| \tag{13}$$

閾値以上の Δx_t の数（1ヶ月当たり）：l_{so}

$$l_{so} = \frac{240}{N-1} \sum_{t=2}^{N} f_{so}(\Delta x_t) \tag{14}$$

$$f_{so}(\Delta x_t) = \begin{cases} 1 & \text{if } \Delta x_t > \gamma_{f_{so}}, \\ 0 & \text{otherwise} \end{cases} \tag{15}$$

ここで f は Δx が閾値以上であるかの判定を行っていて，γ_f は閾値である．この特徴量を計算することにより，計測値の正の方向への急激な変化を抽出することができる．

閾値以下の Δx_t の数（1ヶ月当たり）：l_{sw}

$$l_{sw} = \frac{240}{N-1} \sum_{t=2}^{N} f_{sw}(\Delta x_t) \tag{16}$$

$$f_{sw}(\Delta x) = \begin{cases} 1 & \text{if } \Delta x_t < \gamma_{f_{sw}}, \\ 0 & \text{otherwise} \end{cases} \tag{17}$$

ここで g は Δx が閾値以下であるかの判定を行っていて，γ_g は閾値である．この特徴量を計算することにより，計測値の負の方向への急激な変化を抽出することができる．

閾値以上の $\Delta x_{lpf,t}$ の数（1ヶ月当たり）：$l_{lpf,so}$

$$l_{lpf,so} = \frac{240}{N-1} \sum_{t=2}^{N} f_{so}(\Delta x_{lpf,t}) \tag{18}$$

$\hat{l}_{lpf,so}$ は $\hat{l}_{so}$ と比べて，ローパスフィルタ適用後の時系列を用いて特徴抽出をしているため，より大域的な変動を抽出することができる．

Δt 間の計測値の傾きの平均：$\mu_{x'_t}$

計測値 $\boldsymbol{X}$ における Δt 間の傾きを次式で定義する．

$$x'_t = \frac{x_{t+\Delta t} - x_t}{\Delta t} \tag{19}$$

正常なセンサの計測値の傾きは，センサ間である程度近いと考えられるため，計測値の傾きの平均を特徴量とする．また，給油回数によるばらつきを防ぐため，Δt 間に給油時刻が含まれる場合は平均の計算に含めない．

$$\mu_{x'_t} = \frac{1}{N - K\Delta t} \sum_{t=1}^{N-\Delta t} g_{\mu}(x'_t) \tag{20}$$

$$g_{\mu}(x'_t) = \begin{cases} 0 & \text{if } \exists t_{s,k} \in \mathbb{N}, t \le t_{s,k} \le t + \Delta t, \\ x'_t & \text{otherwise} \end{cases} \tag{21}$$

Δt 間の計測値の傾きの分散：$\sigma^2_{x'_t}$

ノイズや計測値の減少により異常なセンサの計測値の傾きは分散が大きくなると考えられるため，x'_t の分散を特徴量とする．$\mu_{x'_t}$ と同様に，給油回数によるばらつきを防ぐため，Δt 間に給油時刻が含まれる場合は分散の計算に含めない．

$$\sigma^2_{x'_t} = \frac{1}{N - K\Delta t} \sum_{t=1}^{N-\Delta t} (g_{\sigma^2}(x'_t) - \mu_{x'_t})^2 \tag{22}$$

$$g_{\sigma^2}(x'_t) = \begin{cases} \mu_{x'_t} & \text{if } \exists t_{s,k} \in \mathbb{N}, t \le t_{s,k} \le t + \Delta t, \\ x'_t & \text{otherwise} \end{cases} \tag{23}$$

閾値以下の $|x'_t|$ の数（1ヶ月当たり）：$l_{x'_t}$

図 3 の (a) のセンサは，正常センサと比べて $|x'_t|$ が 0 に近い値をとる期間が存在する．このような特徴を表現するために，閾値以下である $|x'_t|$ の数をカウントして，1ヵ月で正規化した値を特徴量とする．

$$l_{x'_t} = \frac{240}{N - \Delta t} \sum_{t=1}^{N-\Delta t} h(x'_t) \tag{24}$$

$$h(x'_t) = \begin{cases} 1 & \text{if } |x'_t| \leq \gamma_{|x'_t|}, \\ 0 & \text{otherwise} \end{cases} \tag{25}$$

ここで h は $|x'_t|$ が閾値以下であるかの判定を行っており，$\gamma_{|x'_t|}$ は閾値である．

4.3 異常変動検知（給油間期間）

時系列の長さに対して異常が発生している期間が短い場合，異常部位が正常部位に埋もれて特徴抽出が困難である可能性がある．したがって本節では，計測値を給油時刻から次回給油時刻までで区切った期間を一つの時系列として扱う異常検知手法を提案する．提案手法では異常変動検知（1 シーズン）と同様に時系列から固定長の特徴量を抽出して，単純な分類器で教師あり学習を行う．教師ラベルは正常と異常の 2 種類で，給油時刻から次回給油時刻までの計測値に対してアノテーションを行う．抽出する特徴量を表 1 に示す．計算方法は 4.2 節と同じである．

表 1: 特徴量（給油間期間）

記号	特徴量
N	時系列のステップ数
d	ノイズの強さ
l_{so}	閾値以上の Δx_t の数（1ヶ月当たり）
l_{sw}	閾値以下の Δx_t の数（1ヶ月当たり）
$\mu_{x'_t}$	Δt 間の計測値の傾きの平均
$\sigma_{x'_t}$	Δt 間の計測値の傾きの分散
$l_{x'_t}$	閾値以下の $\lvert x'_t \rvert$ の数（1ヶ月当たり）

5 実験

本論文で提案した給油時刻推定と異常変動検知の有効性の検証を行う．扱うデータはセンサ計測値と，各灯油タンクへの給油時刻と給油量が記録された給油履歴である．

5.1 実験設定

5.1.1 給油時刻推定

正常データに対して給油時刻を正しく推定できることを確認するために，異常が少ないセンサを 10 個サンプリングして実験する．また推定における最適なパラメータ探索のため，$\gamma_{\Delta x_t}$ と α を変化させて評価値を計算する．給油直後の計測値のサンプリング数 n は全センサで 5 と設定する．評価方法については，給油時刻を陽性，給油時刻以外を陰性として (12) 式で計算できる F1 スコアを用いて比較を行う．

表 2: 給油時刻推定の F1 スコア

	$\gamma_{\Delta x_t}$			
α	50	100	150	200
10^{-1}	0.77	0.78	0.77	0.74
10^{-3}	0.91	0.92	0.91	0.84
10^{-5}	0.93	**0.94**	0.93	0.90
10^{-7}	0.91	0.91	0.92	0.90
10^{-9}	0.91	0.91	0.92	0.90

5.1.2 異常変動検知

各特徴量の計算に用いるパラメータは，検証用データに対して単一の特徴量に閾値を設けて分類を行い，AUC_{PR} が最大となるものを使用する．検証用データは様々な異常が含まれるようにサンプリングしたセンサ 10 個分の時系列を使う．分類器の比較には，ロジスティック回帰（LR），ランダムフォレスト（RF），サポートベクターマシン（SVM）を用いる．実験に使うデータ数は，異常変動検知（1 シーズン）がセンサ 200 個分の時系列で，異常変動検知（給油間期間）が給油間期間 1000 個分の時系列である．扱うデータの期間は 2021 年 10 月 1 日から 2022 年 5 月 1 日の 7ヶ月とし，間訓練データとテストデータの割合は，異常変動検知（1 シーズン）では 5:5，異常変動検知（給油間期間）では 7:3 とする．異常ラベルを陽性，正常ラベルを陰性として (10)〜(12) 式で計算できる精度，再現率，F1 スコアと，PR 曲線の下面積である AUC_{PR} で評価し，分類器の比較を行う．また，提案手法との比較のため，テストデータに対して単一の特徴量に閾値を設けて分類（SFM：Single Feature Model）を行い評価する．SFM の実験は全ての特徴量に対して行い，最も AUC_{PR} が高かった特徴量の実験結果のみを掲載する．

5.2 実験結果

5.2.1 給油時刻推定

給油時刻推定の実験結果を表 2 に示す．表 2 より，検証したパラメータの大半が 90%以上の精度を示した．また，$\alpha = 10^{-5}$，$\gamma_{\Delta x_t} = 100$ のとき最も良い精度を示し，F1 スコアが 0.94 となった．したがって以降は，このパラメータを使って実験を行う．

5.2.2 異常変動検知（1 シーズン）

異常変動検知（1 シーズン）の実験結果を表 3 に示す．精度，再現率，F1 スコアは F1 スコアが一番高くなるような閾値設定での値を載せている．AUC_{PR} は SVM が最も高く，精度，再現率，F1 スコアは LR が

表 3: 異常変動検知（1 シーズン）の実験結果

	AUC_{PR}	precision	recall	F1score
SFM	0.52	0.58	0.52	0.55
LR	0.84	**0.80**	**0.85**	**0.82**
RF	0.73	0.67	0.73	0.70
SVM	**0.86**	0.77	0.82	0.79

表 4: 異常変動検知（1 シーズン）混同行列

	predict	
true	anomaly	normal
anomaly	27	6
normal	8	59

表 5: 異常変動検知（給油間期間）の実験結果

	AUC_{PR}	precision	recall	F1score
SFM	0.55	0.58	0.56	0.57
LR	**0.88**	**0.85**	**0.81**	**0.83**
RF	0.82	0.77	0.84	0.80
SVM	**0.88**	0.84	**0.81**	0.82

表 6: 異常変動検知（給油間期間）混同行列

	predict	
true	anomaly	normal
anomaly	47	11
normal	8	233

最も高いことが分かる．また，AUC_{PR} が最も高かった SVM の F1 スコアが最も高い閾値設定での混同行列を表 4 に示す．表 4 より，異常センサの 82%を検知可能であり，異常センサであると予測したセンサのうち 77%が正しく分類できていることが読み取れる．これは SFM と比較して大幅に精度が向上しており，且つ，提案手法の目的である故障センサ検出システムとして，労働者の負担を十分減らせる結果であるため，提案手法の有効性を示すことができた．

5.2.3 異常変動検知（給油間期間）

異常変動検知（1 シーズン）の実験結果を表 5 に示す．精度，再現率，F1 スコアは F1 スコアが最も高くなるような閾値設定での値を載せている．全ての評価指標において LR と SVM が同水準で良い性能を発揮している．AUC_{PR} が最も高かった LR の F 1 スコアが最も高い閾値設定での混同行列を表 6 に示す．表 6 より，異常な給油間期間の 81%を検知可能であり，異常な給油間期間であると予測した時系列のうち 85%が正しく分類できていることが読み取れる．異常変動検知（1 シーズン）と同様に，SFM と比較して大幅に精度が向上している．また，表 3 の結果と比較しても同水準の性能を発揮していることから，時系列を短くしても提案手法が有効であることを示すことができた．さらに，異常変動検知（1 シーズン）との比較のため，異常変動検知（1 シーズン）では偽陰性（FN）となっていたセンサの分類結果を可視化したものを図 4 に示す．赤い点線がタンクに給油した時刻を表し，黄色で色付けされた期間が提案手法により異常であると推定された給油間期間である．異常変動検知（1 シーズン）では時系列の長さに対して期間が短いため検知できなかった異常が，時系列を給油間期間で区切る異常変動検知（給油間期間）では検知できることが読み取れるため，提案手法の有効性を示すことができた．一方で，図 5 に偽陰性の例を示す．図 5 では，1 月末から 2 月末までの給油間期間の一部で異常が見られるが，提案手法では異常を検知できていない．これは，異常変動検知（1 シーズン）のときと同様に異常が発生している期間が扱う時系列と比べて極端に短いため，十分に特徴抽出できずに偽陰性になったと考えられる．

6 まとめ

本論文では，センサの計測値と給油時刻データから灯油タンクへの給油時刻を推定する手法と，給油時刻推定の F1 スコアとその他計算可能な特徴量を用いた分類器ベースの異常検知手法を提案した．実データに対して実験を行い，一般的な異常検知問題で扱われる評価指標で評価した結果，どの手法も現実の問題に有効であることを示すことができた．

本論文で提案した異常変動検知では，異常値が計測された具体的な時刻が分からないため，今後は時系列のどこの時刻で異常値が計測されたか分かるような手法を提案する予定である．

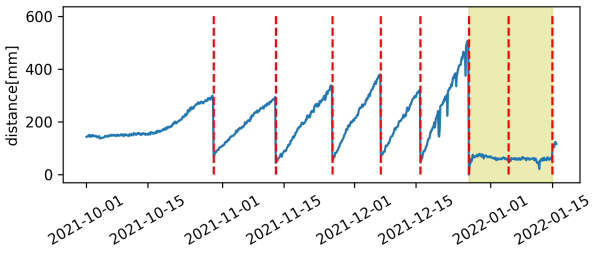

図 4: 分類結果の可視化.

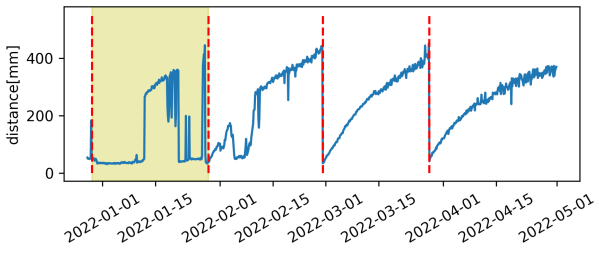

図 5: 偽陰性の例.

謝辞

本研究は，ノーステック財団「研究開発助成事業」の支援を受けて実施されたものです．ここに感謝の意を表します.

参考文献

[1] 大江弘峻, 横山想一郎, 山下倫央, 川村秀憲, 多田満朗. タブーサーチを用いた灯油配送計画の最適化. 第 206 回知能システム研究発表会, 2022.

[2] 劉兆邦, 横山想一郎, 山下倫央, 川村秀憲, 多田満朗. 灯油配送計画決定に向けた多層パーセプトロンを用いた家庭内灯油消費量の推定. 第 21 回複雑系マイクロシンポジウム, 2022.

[3] André Gustavo Maletzke, Carlos Andres Ferrero, Chris Mayara Tibes, Everton Alvares Cherman, and Willian Zalewski. Medical time series classification using global and local feature extraction strategies. *Journal of Health Informatics*, Vol. 9, No. 3, p. 73–80, 2017.

[4] 井上洋思, 石山文彦, 渡辺敏雄, 大山孝. O-028 家庭の電力時系列から得た統計的特徴に基づく家電機器の動作状態推定方法 (o 分野: 情報システム, 一般論文. 情報科学技術フォーラム講演論文集, Vol. 13, No. 4, pp. 379–380, 2014.

[5] 茂木貴弘, 中澤友哉, 田原鉄也. 1d cnn-lstm による調節弁内部の異常検知. 人工知能学会全国大会論文集, Vol. JSAI2018, No. 3, pp. 3Pin144–3Pin144, 2018.

[6] Markus M. Breunig, Hans-Peter Kriegel, Raymond T. Ng, and Jörg Sander. Lof: Identifying density-based local outliers. *SIGMOD Rec.*, Vol. 29, No. 2, p. 93–104, 2000.

[7] Bo Zong, Qi Song, Martin Renqiang Min, Wei Cheng, Cristian Lumezanu, Daeki Cho, and Haifeng Chen. Deep autoencoding gaussian mixture model for unsupervised anomaly detection. In *International Conference on Learning Representations*, 2018.

[8] Lifeng Shen, Zhuocong Li, and James Kwok. Timeseries anomaly detection using temporal hierarchical one-class network. In *Advances in Neural Information Processing Systems*, 2020.

[9] Youjin Shin, Sangyup Lee, Shahroz Tariq, Myeong Shin Lee, Okchul Jung, Daewon Chung, and Simon S. Woo. Itad: Integrative tensor-based anomaly detection system for reducing false positives of satellite systems. In *Proceedings of the 29th ACM International Conference on Information & Knowledge Management*, 2020.

[10] Zhihan Li, Youjian Zhao, Jiaqi Han, Ya Su, Rui Jiao, Xidao Wen, and Dan Pei. Multivariate time series anomaly detection and interpretation using hierarchical inter-metric and temporal embedding. In *Proceedings of the 27th ACM SIGKDD Conference on Knowledge Discovery & Data Mining*, 2021.

[11] Thomas Schlegl, Philipp Seeböck, Sebastian M. Waldstein, Georg Langs, and Ursula Schmidt-Erfurth. f-anogan: Fast unsupervised anomaly detection with generative adversarial networks. *Medical Image Analysis*, Vol. 54, pp. 30–44, 2019.

[12] Kyle Hundman, Valentino Constantinou, Christopher Laporte, Ian Colwell, and Tom Soderstrom. Detecting spacecraft anomalies using lstms and nonparametric dynamic thresholding. In *Proceedings of the 24th ACM SIGKDD International Conference on Knowledge Discovery & Data Mining*, 2018.

[13] Jiehui Xu, Haixu Wu, Jianmin Wang, and Mingsheng Long. Anomaly transformer: Time series anomaly detection with association discrepancy. In *International Conference on Learning Representations*, 2022.

[14] 今城勝治, 吉永秀雄, 亀山俊平. 位相差方式 tof センサと車両・車軸検知応用. 計測と制御, Vol. 59, No. 5, pp. 321–325, 2020.