

社会システムから見た障害予兆検知技術について

Study on Failure Prediction for Social Systems

三木 良雄†
Yoshio Miki

1. まえがき

近年ビッグデータのブームと、建物や道路設備の老朽化の観点から、設備の障害予測が注目されている。しかしながら、人間が想定していない障害までも予測したいとか、予兆を検出できるのかという議論にまで至ると未だ曖昧な部分が多いように思われる。この種の曖昧性を払拭するためには、異常とは何か、またその判断とは何かの明確な定義が必要である。また、その定義にそくしたデータ分析手法の確立が必要である。

本稿では異常の分類とその検出に関わる分類整理を行い上記観点に基づく問題提起をする。加えて、異常を稼働中に検出する方法に関して基本的な方針を提案する。

2. 異常と正常の考え方

提起している課題説明には「異常」の定義が重要である。図 1 は本研究にて提唱する異常状態と正常状態の違いや包含関係を示したものである。

一番明確な定義は、いつもと違う状態が異常、いつもと同じ状態を正常とする考え方である。応用面では定常運転が常である機械、電気系機器の振動や回転数、あるいはトランザクション量やデータ量が決まっている IT システムなどが該当する。この種の異常を検知する方法論としては、いわゆる統計的に観測対象の状態(の確率分布)や動作モデル自身を推定し、その定常状態からはずれたときに、異常であるとする考え方が一般的である。具体的には、回帰モデルや確率モデルに基づく推定による方法である。近年では機械学習として、統計的推定手法が障害検知や障害予知の手法として活用されている[1,2]。

機械学習に代表されるように、学習のためには、何が正常で何が異常であるのかが、予め与えられなければならない。近年のビッグデータや人工知能ブームでは、学習データに全く含まれていなかった完全に異なるケースでも異常を判別できるかのような誤解が少なからずあるように思われる。ビジネスとしての機器設計や保守という観点からは「異常」とは設計時点で何を想定していたのかで定義される。つまり、設計者が設計前提としていた強度や状態の範囲内であれば正常であり、その範囲を逸脱した場合、それが異常という定義となる。このような異常の検知にはデータの分析というよりも、設計前提となっている数値もしくは状態をモニタリングできるか否かが重要な観点となる。しかし、保守などまでを考えた場合、機器や構造物の内部のように全ての箇所をモニ

タリングできる訳ではないため、モニタリングできる箇所とモニタリングしたい箇所を関連づけるモデルが先に述べた異常、正常の議論同様に必要となる場合もある。

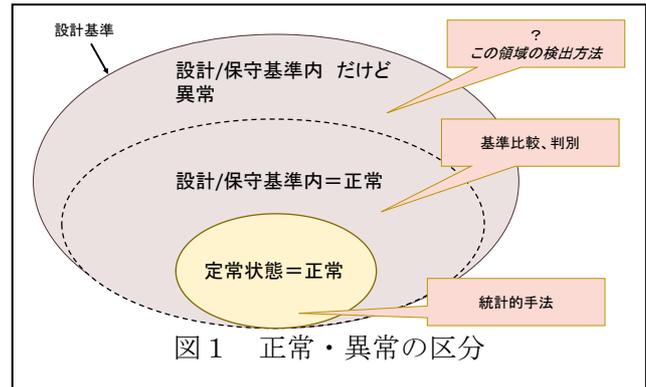


図 1 正常・異常の区分

ここで、社会的に注目されている障害、異常について見てみると、“設計的には想定外であった、あるいは保守点検時には異常はなかった”にも関わらず重大な事故や被害に至る事象が関心を集めていると考えられる。換言すれば、この種の異常を検知する方法論があるのか否かの議論が重要だと考えられる。図1の分類では先に述べた設計で想定していた範囲の外に位置づけられるが、厳密には、結果論的に設計時の最悪ケースとして想定できた状態と同じ障害、被害に至っているケースと、被害や障害そのものが誰にも予測できていなかったケースに分けて考えることができる。

3. 想定外異常の検証方法 [4]

本稿では、前章で述べた“設計で想定した被害と同じことが起こる”にも関わらず、設計基準値の範囲内であるという状態の検出方法について考察する。

このような、“設計で本来は考慮すべきであったのにも関わらず、ヌケやモレとなってしまいう事象”を検出するためには、FMEAといった手法が古くから知られている。FMEAでは考え得る障害をできるだけ網羅的に列挙し、対象としている設計に照らし合わせたときに、抜けている状態があるか否かを検討する。本来はある程度の経験知を持った人間で行うものであるが、本稿では先に述べた機械学習等によって、観測対象の機器の状態やモデルを検出する方法と、その文脈とは全く異なる角度から、起きてはならない障害について半構築状態にあるモデルに照合する方式を提案する(図2)。この方法によれば、構築途中のモデルが外部から与えた障害を受け入れられる場合、潜在的障害モードが発見されたと考える。

† 工学院大学 情報学部 システム数理学科

4. 時系列観測データに基づく想定外検証方法

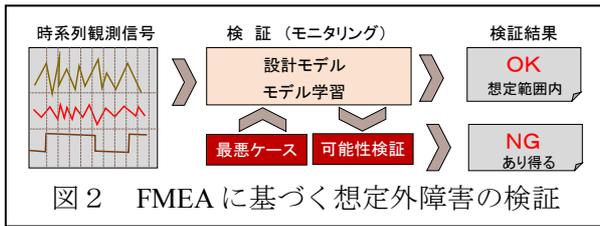


図2 FMEAに基づく想定外障害の検証

前章で述べた想定外異常の検証方法をデータ分析の観点から述べる。本研究が対象としている機械、構造物の場合、観測されるデータは日々の運転状況や保守用の監視データ、すなわち複数種の時系列データとなる。また、設計時の前提条件や設計モデルが存在するという前提を置くことが可能である。

以上のような条件から、状態空間モデルのように設計モデルから比較的正確な状態モデルを作成することが可能な分析手法が適当と考えられる。しかしながら、前章で述べたように、本手法では設計時に前提条件として考えていなかった事項を事後に追加するという観点、および新たに想定した事象について障害発生の有無というよりも障害が発生している可能性（＝確率）の議論が中心となるため、ベイズ統計での実装法を検討する。

$$P(H|D) = \frac{P(D|H) P(H)}{P(D)} \quad \dots\dots (式1)$$

ベイズ推論では（式1）に示すベイズの公式に基づき、随時入力されるデータ D に関して、事後確率 $P(H|D)$ を計算し、その事後確率を次のデータに関する $P(H)$ として用いることで、この基本式自身が入力データに関する正常と異常の判別能力を取得していくことになる。ここに、 D は判定対象の入出力データであり、 H は正常、異常の状態である。また、 H に関しては後に正常、異常の判定根拠となる中間状態も含ませることにする。

以上の前提から、3章で述べた FMEA 的な検証を次のように考える。

- (1) 初期の事前確率 $P(H)$ は経験値としての障害率を基に与える。
- (2) 尤度 $P(D|H)$ は系の異常および正常時における観測データの確率、つまり設計上想定される状態であり、設計上の前提状態として考える
- (3) ベイズ推定によって設計上の正常、異常状態を確率として学習させる
- (4) 設計時に想定した異常の原因となるものの発生確率としては極めて低く、0としていた条件を H の項目として追加する (H_s)。 (正確には異常仮説の原因となる新たな仮説として追加)
- (5) 初期の $P(H|H_s)$ は非零の極小値とし、(3)の学習を継続させる。

3章において想定から抜けていた場合とした状態を途中に想定し、途中段階で異常と判定される新たな因果関係を挿入する点が要点となる。このイメージを表現した

のが（図3）であるが、異常 (H_a : abnormal) と判定される因果関係グラフにおいて、通常的设计判断として、“状況としてはあり得るが極めて稀な状態＝想定外”としていた状況を“想定できるのであれば、小さな確率であっても因果関係として想定する”という形に変更することを意味する。つまり、元の設計前提として想定していなかった状態 (a) に対して、全く想定していなかった状態を挿入するのではなく、改めて設計レビュー的な観点で、想定できることを復活させるが如く、異常に至る可能性（仮説）を因果グラフ中に挿入する考え方である。

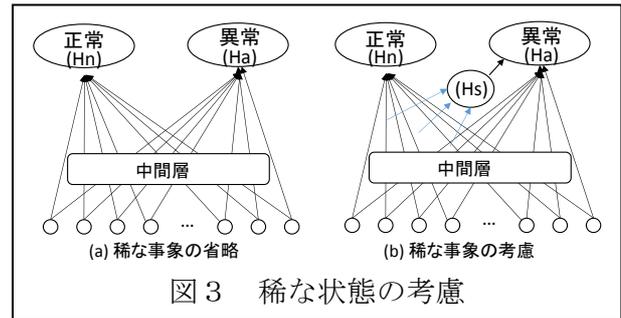


図3 稀な状態の考慮

5. まとめおよび今後の課題

想定外の異常検出、検証方法を述べたが、この考え方は設計当初から微小でも可能性がある状態をモデル化しておくことも可能であるし、また途中段階で随時、状態を追加して行くことも可能である。

本報告では考え方を示すにとどまっているが、単純なベイズモデルでは精度に対して疑問もあり、実際のシステムにおける障害診断や予兆に適用し、その実用性を検証する必要がある。

参考文献

- [1] 鈴木忠志, 野田統治郎, 渋谷久恵, 鈴木英明, “高度保守サービスに貢献する予兆診断システム”, 日立評論, Vol.95, No.12, pp.37-40, 2013年
- [2] 中村 隆顕, 今村 誠, 立床 雅司, 平井 規郎, “標本部分列を用いた時系列データ異常検知方式”, 電気学会論文誌C, Vol. 136, No. 3, pp. 363-372, 2016年
- [3] 井手剛, “入門 機械学習による異常検知”, コロナ社, 2015年
- [4] 三木良雄, “想定外障害の検出について”, 電子情報通信学会総合大会, A-10-12, 2016年
- [5] 樋口知之, “予測にいかす統計モデリングの基本”, 講談社, 2011年
- [6] 伊庭幸人, “ベイズ超速習コース”, 岩波データサイエンス, Vol. 1, pp. 6-16, 2015年