

特徴学習を用いた車両の早期故障検出・要因解析支援法

Feature Learning to Support Fault Detection and Analysis of Vehicle

田川 貴章^{*1} 佐藤 守一^{*1} 佐野 範佳^{*1}
Takaaki Tagawa Shuichi Sato Noriyoshi Sano

^{*1}株式会社豊田中央研究所
TOYOTA CENTRAL R&D LABS., INC.

This paper proposes a new approach which can both detect and analyze unknown faults precisely. Our approach uses Overcomplete Independent Component Analysis for fault detection and analysis and strongly assists experts to diagnose complex and extensive systems. In contrast to conventional approaches which have pursued fault detection performance at the expense of fault analysis ability, our approach succeeded to achieve both high fault detection and analysis performances without relying on any prior information about the faults. Using driving data, change detection experiments have shown that the fault detection performances of our approach are competitive to or outperform other conventional methods even if they are non-linear models such as kernel-based or mixture-based models. Additionally, our fault analysis approach could extract the combinations of attributes which express the essential differences between nominal data and test data.

1. はじめに

車載システムへの高い信頼性を確保するため、開発者はリリース前に多岐に渡るテストを行う必要がある。その際に1つでも不明な故障が見つかった場合、それらは解析・特定され対策が取られる。これらの故障検出・要因解析プロセスは基本的に専門家知識に基づいて行われる。しかしながら、車載システムが今後複雑化・大規模化していくに連れて専門家知識に基づく解析は高コストになる恐れがある。

そうした背景の中、データに基づく故障検出・要因解析支援技術に注目が集まっている。この技術の利用により専門家知識に負う所が少なくなるため、解析コストの低減が期待される。想定する問題設定は、正常とみなされた機器より得られるデータよりモデルの学習を行い、そのモデルを用いて正常かどうか不明な同様の機器より得られたテストデータを評価する事でその機器に故障が発生しているか否か、発生しているならば具体的にどの部分において故障が発生しているかの判断を、データの観点から支援する事である。関連技術としては Multivariate Statistical Process Monitoring(MSPM)がある。この技術は主に化学プラント等のプロセス管理技術として広く用いられている。主な手法としては Principal Component Analysis (PCA) に基づく手法があり、 T_2 統計量並びに Q 統計量を用いてデータ評価を行うのが特徴である。特に、 Q 統計量に基づき、検出された故障データに対し、観測している系列においてどの系列が最もその故障へ寄与しているかを解析する事が可能である。診断者はこの寄与度の分布に基づき原因の推測をより容易に行う事が可能になる [Ge 12]。しかしこの手法は学習する正常データに対してガウス性を仮定しており、車両の走行データなどの非ガウス性を持つデータに対しては十分な性能を発揮する事が難しい。そのため学習するデータ分布に対してガウス性を仮定しない Independent Component Analysis (ICA) に基づく手法も提案されている。故障検出は ICA により抽出された特徴空間上で行われ、しきい値の設定、あるいは多変量カーネル密度推定や Support Vector Data Description (SVDD)

といった手法を用いて監視する事で検出を行う [Ge 12]。これらの手法は故障検出性能が向上するが、いずれも特徴空間への写像を行う関係より元のデータとの関連が複雑で要因解析を行う事が困難である。一方 PCA を区分線形混合モデルへ拡張した Mixture of Probabilistic Principal Component Analysis (MPPCA)[Tipping 99] は各コンポーネント上では PCA に基づいているため上記 PCA 単独による手法と同じく要因解析を行う事が出来る。ただこの手法での要因解析がどの程度有効なものかは現状深く考察されては無い。

本論では上記背景に基づき、高い故障検出性能及び要因解析能力を有する解析支援技術の提案を行う。この手法では Overcomplete Independent Component Analysis を用いた元のデータ系列数のより多い数の独立成分を抽出する事で特徴抽出性能を向上させ、また各独立成分を別々に単変量の Kernel Density Estimator を用いて評価する事で全体の故障確率を評価する。さらに各独立成分毎に正異常判定を行う事で正常な成分のみを抽出、擬似逆行列により元データ空間へ再構成し元データとの差分を取る事で異常に寄与した部分のみを抽出し高性能な要因解析を可能にした。さらに、データ点毎の解析ではなくデータ群に対してまとめて要因解析を行い散布図にて可視化する事で、従来のデータ点毎の解析では見えない動的な変化を分かりやすく診断者へ提示する。

本論の構成は以下の通りである。まず次章にて提案する手法について述べる。続く3章にて今回行った車両走行データを用いた実験内容及び結果について述べる。4章で実験に対する考察をまとめ、最後5章にて結論を述べる。

2. 提案手法

本章では提案する故障検出・要因解析手法について述べる。最初にベースとなる技術である Overcomplete Independent Component Analysis (OICA) 及び Kernel Density Estimator (KDE) の概要について述べる。その後、これら技術を用いた故障検出・要因解析技術を提案する。

連絡先: 田川 貴章, 株式会社豊田中央研究所, 愛知県長久手市横道 41-1, tagawa@mosk.tytlabs.co.jp

2.1 Overcomplete Independent Component Analysis

OICA は Independent Component Analysis (ICA)[Hyvärinen 00] を過完備 (Overcomplete) なモデルに拡張したものとなる。今, i.i.d. な n 個の正常な観測データサンプル $\{x^{(1)}, \dots, x^{(n)}\}$ が得られたとする。この時, 各サンプルは m 個の系列 $x = \{x_1, \dots, x_m\}$ で構成されるとする。また各系列は平均 0, 分散 1 へ標準化が行われているものとする。ICA では, $k (\leq m)$ 個の互いに独立な独立成分 $s = \{s_1, \dots, s_k\}$ を仮定し, 以下で示すモデルを仮定する。

$$x = As. \quad (1)$$

ここで A は混合行列と呼ぶ。ここで混合行列 A 及び s を同時に求める代わりに上式を

$$s = Wx, \quad (2)$$

と変換する事で独立成分 s の独立性を最大化するような $W = A^{-1}$ を求める問題に帰着させる。この最適化に当たっては, すでに様々な手法は提案されている ([Hyvärinen 00] 参照)。

上記 ICA に対し, OICA では独立成分の個数が元のデータ系列数より多い場合 ($k > m$) を想定する。このモデルを用いるに当たって, 独立成分へ事前分布を仮定する。今回 Laplace 分布を事前分布として採用し, 以下に示す生成モデルを定式化する。

$$p(x) = \frac{\prod_{i=1}^k \exp(-|w_i x|)}{Z}. \quad (3)$$

ここで w_i は分離行列 $W = \{w_1^T, \dots, w_k^T\}^T$ の各行成分を表し, Z は正規化定数を表している。ここで Z は解析的に計算不可なため最適化が困難であるが, 今回 Score Matching 法に基づくスコア関数を最小化する事で Z を計算する事なく最適化計算が可能になる [Hyvärinen 05]。

2.2 Kernel Density Estimator

Kernel Density Estimator (KDE)[Silverman 86] はカーネル関数を用いる事で単変量分布を精度良く近似する事が出来る。今回提案する手法は前節で述べた OICA による抽出された独立成分 s の各成分毎の単変量分布を学習するために用いる。

今, n 個の正常な観測データサンプルに対して得られた i 番目の独立成分を $\{s_i^{(1)}, \dots, s_i^{(n)}\}$ とする。ここで新たなテストサンプル $s_i^{(n+1)}$ が得られたとするとその確率密度は以下で推定される。

$$f(s_i^{(n+1)}) = \frac{1}{nh} \sum_{l=1}^n k_h \left(\frac{s_i^{(n+1)} - s_i^{(l)}}{h} \right). \quad (4)$$

ここで h はハイパーパラメータである。 $k_h(\cdot)$ はカーネル関数であり, 以下に示す標準ガウス関数を用いた。

$$k_h(s_i^{(n+1)}) = \frac{1}{\sqrt{2\pi}} \exp\left(-\frac{1}{2}\left(\frac{s_i^{(n+1)}}{h}\right)^2\right). \quad (5)$$

2.3 故障検出支援法

本提案手法における故障検出支援は OICA により抽出された独立成分の同時確率に基づいて行う。この時, 各独立成分 $s_i, i = 1, \dots, k$, に対し独立性を仮定し以下に示すように負の対数同時確率を近似的に計算する。

$$-\log p(s) \approx -\log \prod_{i=1}^k p(s_i) = -\sum_{i=1}^k \log p(s_i). \quad (6)$$

この値を今回故障確率とし, 値が大きいくほど故障している可能性が高いと診断者は判断出来るこの時 $p(s_i)$ の計算には UKE を用いて近似的に行う。

2.4 要因解析支援法

要因解析支援では OICA による抽出された各独立成分 s_i それぞれに対して正異常判定を行い, 正常と判定された因子のみでデータ再構成を行い, 元データとの差分を取る事で異常に寄与した部分のみを抽出する。

今, 各独立成分に対する負の対数確率 $-\log p(s_i)$ に対ししきい値 t_i を設定する。今回, 正常データに対して得られる故障確率 $-\log p(s_i)$ の最大値をしきい値として用いる。今 m 系列のテストサンプル x が与えられた際, それに対応する i 番目の独立成分 s_i において $-\log p(s_i) > t_i$ であった場合にその i 番目の独立成分は異常であると判定する。ここで少なくとも 1 つの独立成分が異常と判定された場合, つまり $k_1 (< k)$ 個の独立成分が正常と判定された場合を考え, 正常な因子のみで構成される独立成分を s_1 とおく。次に分離行列 W に対する混合行列 A を擬似逆行列により $A = (W^T W)^{-1} W^T$ で近似する。この中で, 抽出された正常な独立成分 s_1 に対応する部分行列を $A_1 \in \mathbb{R}^{m \times k_1}$ とすれば, 正常な独立成分を用いた再構成データ x_1 は

$$x_1 = A_1 s_1, \quad (7)$$

で与えられる。ここで元データとの差分 $x - x_1$ は異常な独立成分で構成されるため, これを解析する事でどの部分が異常に寄与しているか精度良く見積もる事が可能になる。具体的には, 各データ系列毎に差分データの大きさを計算し, それが大きい順に異常への寄与度が高いとみなす。

2.5 複数サンプルへの要因解析

本手法における要因解析では複数サンプルへまとめて要因解析を行う事を想定する。複数サンプルに対する要因解析を行う事で分布レベルの変化を抽出する事が可能になる。

複数サンプルへの要因解析は前節で述べた寄与度計算に基づき, 以下のように行う。

1. 各サンプル毎に各データ系列毎の寄与度を算出し, 最も大きく寄与した上位 1, 2 位の系列を抽出する;
2. 全サンプルで抽出した 2 つの系列組が何回抽出されたかカウントする;
3. 抽出数が多い順に各系列組の散布図を, 学習正常データと解析したデータに対して表示する。

今回上位 2 位までの系列に限ったのは, 後に散布図として表示する事が可能だからである。散布図は統計に詳しくない診断者でも理解しやすく, また分布レベルの違いを捉える事が容易である。

3. 車両走行データによる実験

本節では, 走行環境の変化を擬似的に故障として扱う事で, 提案手法の故障検出・要因解析性能を評価した結果を述べる。

3.1 実験データ

自動車用の故障診断テスターを用い自動車の走行データ取得を行った。取得した信号系列は全部で 43 系列である。データ取得に当たってはいくつかの走行条件を設定し, それに基づいて 1 名のドライバーのみで全てのデータ取得を行った。各データの名前及び対応する取得条件, 取得サンプル数を表 1 にまと

める．ここで Control にある Power, Eco, Normal, Brake, Neutral はそれぞれ自動車の走行制御設定等を示し自由に選択可能である．データは Straight, Upslope, Downslope, Curve それぞれの道路条件にて同様の加速, 減速走行を行った．ただし Slow 走行では通常の直線走行時よりも弱い加速, 減速を行った．また Weight データでは 200[kg] の重りを積載して走行し, DtoN データでは加速後に Neutral へ変更して走行している．Power データは今回正常データとして想定し, 前処理として正常データに対し平均 0, 分散 1 になるよう標準化を行い, 整合性を取るため同じ処理を他のデータにも適用した．

表 1: 実験条件

Name	Condition	Control	Samples
Power	Straight	Power	1450
Eco	Straight	Eco	561
Normal	Straight	Normal	608
ShiftB	Straight	Brake	591
Slow	Straight	Power	737
DtoN	Straight	Neutral	418
Weight	Straight, 200[kg] loaded	Normal	406
Curve	Curved	Power	214
Down	Downslope	Power	92
Up	Upslope	Power	100

3.2 比較手法

今回比較に用いた手法を表 2 にまとめる．OICA-KDE は今回提案する手法で独立成分数を $k = 200$ として OICA を学習した．この時 OICA を適用する前に PCA による白色化及び 1[%] ノイズ除去を行っている [Hyvärinen 00]．また KDE に関して (4) 式にあるハイパーパラメータ h はヒューリスティクスに基づく式

$$h = \left(\frac{4\hat{\sigma}^5}{3n} \right)^{\frac{1}{5}}, \quad (8)$$

で求めた [Silverman 86]．ここで n は学習に用いた正常データサンプル数, $\hat{\sigma}$ は標本分散である．OICA-SVDD は KDE の代わりに, MSPM において良く用いられる従来手法である Support Vector Data Description (SVDD)[Tax 04] を用いたものである．SVDD のハイパーパラメータ C は $\{0.001, 0.01, 0.1, 1, 10, 100\}$ の間で最も故障検出性能が良かったものを採用した．また利用するカーネル関数として以下に示す RBF ガウスカーネルを用いた．

$$k(\mathbf{x}^{(i)}, \mathbf{x}^{(j)}) = \exp\left(-\frac{\|\mathbf{x}^{(i)} - \mathbf{x}^{(j)}\|^2}{2\sigma^2}\right). \quad (9)$$

ハイパーパラメータの σ は $\text{median}\{\|\mathbf{x}^{(p)} - \mathbf{x}^{(q)}\|\}$ により求めた．ここで $\mathbf{x}^{(p)}$ は p 番目の正常データサンプルを示す．Kernel Principal Component Analysis (KPCA)[Hoffmann 07] はカーネルに同じく RBF ガウスカーネルを用い, 主成分空間における次元数 d はスクリープロットに基づきながら $\{2, \dots, 9\}$ のうちで最も故障検出性能が良かったものを採用した．最後に Mixture of Probabilistic Principal Component Analysis (MPPCA)[Tipping 99] は次元数 d と共にクラスタ数 c を $\{2, \dots, 9\}$ の間で変化させ最も故障検出性能が良かったものを採用した．

表 2: 比較手法

Approaches	Parameters
OICA with KDE (OICA-KDE)	k, h
OICA with SVDD (OICA-SVDD)	k, σ, C
KPCA	d, σ
MPPCA	c, d

3.3 実験結果

3.3.1 故障検出性能実験

この実験では走行条件の変化を故障として擬似的に扱い, その違いをどの程度まで検知出来るかをいくつかの手法で比較した．Power データを正常データとして学習し, それ以外のデータを解析対象データとして評価を行った．

評価手法としては問題を 2 クラス分類問題として扱い ROC (Receiver Operating Characteristics) 曲線による AUC (Area Under the Curve) を用いてその分類性能を評価した．ただし過剰適合を防ぐため正常データの 8 割をランダムに選択し学習データとし, 残り 2 割と各解析対象データを組合せたものを検証データとする．この試行は各解析対象データに対し 10 回繰り返し行い, AUC はそれらの平均値を用いた．以上の実験において得られた AUC の値を表 3 にまとめる．

表 3: AUC

	OICA with		KPCA	MPPCA
	SVDD	KDE		
Eco	0.5486	0.5963	0.5186	0.5753
Normal	0.5114	0.5478	0.4903	0.5471
ShiftB	0.6283	0.5847	0.5436	0.5750
Slow	0.4906	0.6209	0.4811	0.6801
DtoN	0.7002	0.7239	0.5827	0.7052
Weight	0.5484	0.5945	0.5320	0.5827
Curve	0.8374	0.8711	0.8258	0.8791
Down	0.8502	0.8505	0.7563	0.8393
Up	0.8949	0.9378	0.8807	0.9384

3.3.2 要因解析性能実験

この実験では走行条件変化の原因を要因解析によりどの程度抽出可能かその性能を従来手法と比較した．特に事前知識なく要因解析が行え, かつ高性能な故障検出能力も報告されている MPPCA [乾 09] を比較手法にし, 提案する OICA-KDE による要因解析結果との比較を行った．今回学習において今回正常データを特に分割せず全てを用いてモデルを学習した．解析対象は前節の故障検出性能実験において, MPPCA が OICA-KDE より良い結果を出した Slow データに対して今回要因解析を行った．要因解析は第 2.5 節で述べた複数サンプルの要因解析法に基づき Slow データ全サンプルに対して行い, それぞれの手法により抽出された系列組の上位 4 位までをそれぞれ表示させ比較を行った．この時得られた要因解析結果を図 1 へまとめた．

4. 考察

4.1 故障検出性能

表 3 を見ると比較した手法は全て非線形な手法にも関わらず, 提案手法は Eco, Normal, DtoN, Weight, Down において

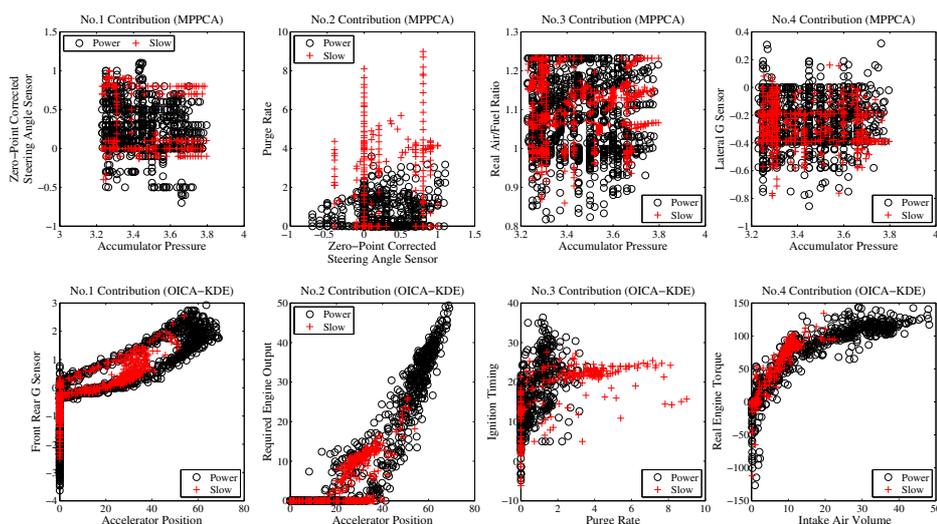


図 1: 上位 4 位までの寄与系列組 (上: MPPCA, 下: OICA-KDE)

最も良い結果を、その他のデータにおいても拮抗する結果を出す事が出来た。また SVDD と KDE の比較では ShiftB 以外はすべて KDE がより良い結果を得ている。これは OICA により抽出される独立成分がより高い独立性を持っているため、(3) 式で示す互いの依存関係を無視した積のモデルによる評価で十分な性能が得られると考えられる。また SVDD は (9) で示す RBF ガウスカーネルを用いているが、この時ノルムにより各変数は和の形で叩き込まれる。すなわち独立成分間の独立性は大きな影響を持たず活用できていないと考えられる。

4.2 要因解析性能

図 1 で示される MPPCA 及び OICA-KDE による要因解析結果を比較すると、MPPCA で抽出された系列組は互いに相関を持たないような組が多いのに対し、OICA-KDE で抽出された系列組は相関を持つものが多く抽出された。MPPCA は、PCA による要因解析がデータの主要な相関を表す主成分空間から直交した距離に基づいたものになるため、それらは互いに相関をもたないようなものが多く、抽出される系列組もそのようなものが多いと考えられる。OICA-KDE は、異常と判定された独立成分を抽出して解析しており、これら独立成分はそれぞれ正常データにおいて学習された特徴になる事から、抽出される系列組も何かしらの特徴、つまり相関関係を持ったものが多くなると考えられる。実際の解析においては、診断者は主に主要な相関上における相関関係の崩れを故障として観測したいため、OICA-KDE による要因解析結果は診断者に有益な情報であると言える。実際 OICA-KDE の結果で、1 番目に寄与が高かった系列組での散布図は、データの変化を本質的に表しておりアクセルに対する加速特性の変化があった事が理解出来る。また今回複数サンプルに渡って同時に要因解析をした事から分布レベルの変化を抽出する事が出来ている。特に OICA-KDE の結果で 2, 4 位の系列組を見ると、サンプル単体では大きなズレはないものの、分布レベルで見ると明らかに変化がある事が分かる。こうした変化はサンプルを 1 つ 1 つ解析する場合だと見つけ辛いものであるため、本手法によりそれらも効率良く抽出出来たと考えられる。

5. 結論

本論では、Overcomplete Independent Component Analysis (OICA) 及び Kernel Density Estimator (KDE) を用いた故障検出・要因解析支援法を提案した。車両走行データによる実験より、この手法は非線形性を考慮しないにも関わらず従来の非線形手法に対して拮抗する、またはより良い故障検出性能を出した。加えて要因解析では複数サンプルの解析でデータの動的な変化を散布図で分かりやすく可視化出来た。

参考文献

- [Ge 12] Ge, Z., & Song, Z. (2012). Multivariate Statistical Process Control: Process Monitoring Methods and Applications. Springer.
- [Hoffmann 07] Hoffmann, H. (2007). Kernel PCA for novelty detection. *Pattern Recognition*, 40(3), 863-874.
- [Hyvärinen 00] Hyvärinen, A., & Oja, E. (2000). Independent component analysis: algorithms and applications. *Neural networks*, 13(4), 411-430.
- [Hyvärinen 05] Hyvärinen, A., & Dayan, P. (2005). Estimation of Non-Normalized Statistical Models by Score Matching. *Journal of Machine Learning Research*, 6(4).
- [Silverman 86] Silverman, B. W. (1986). *Density estimation for statistics and data analysis* (Vol. 26). CRC press.
- [Tax 04] Tax, D. M., & Duin, R. P. (2004). Support vector data description. *Machine learning*, 54(1), 45-66.
- [Tipping 99] Tipping, M. E., & Bishop, C. M. (1999). Mixtures of probabilistic principal component analyzers. *Neural computation*, 11(2), 443-482.
- [乾 09] 乾 稔, 矢入 健久, 河原吉伸, 町田和雄. 次元削減の再構成誤差を用いた異常検知手法の比較, 人工知能学会, 2009.