

油圧式電子制御 AWD システムにおける 油温判別手法の構築

Oil Temperature Classification Method for Hydraulic Electronically Controlled AWD System

吉 野 弘 規*
Hiroki YOSHINO

要 旨

車載制御ユニットへの実装を目的とし、油圧式電子制御 AWD システム内部の油温状態を、少ない計算コストで高精度に判別可能なアルゴリズムを構築した。対象とするシステムは、モータを用いた電動ポンプにより加圧をおこなうシステムのため、油温とモータ電流の間には相関があることが考えられる。システムの構造を理論的に解析することで、モータ電流から油温を判別するモデルは線形モデルで十分であることを導き出し、ロジスティック回帰による判別モデルの構築をおこなった。さらに、判別精度と判別頻度の両立を実現するために、連続した複数回の判別が実行された際の事後確率を、ロジスティック回帰の出力値のみから計算する手法を構築した。実際にシステムから得られたデータに対し本手法を適用することで、高精度に油温の判別が可能であることを確認した。

ABSTRACT

A low computational complexity and high-accuracy method for clarification of oil temperature in a hydraulic electronically controlled rear differential unit was developed for implementation to a vehicle control unit. Because the target system uses a motor-driven electronic hydraulic pump to increase hydraulic pressure, a correlation was considered to exist between oil temperature and motor current. Theoretical analysis of the structure of the system demonstrated that a linear model was sufficient for clarification of the state of oil temperature from motor current, and a clarification model for the state of oil temperature using logistic regression was formulated. In addition, in order to balance accuracy and frequency of clarification, a method of calculation of posterior probability when continuous multiple clarifications were executed using only the output of the logistic regression model was developed. The results of application of the method to data obtained from the actual target system confirmed that the proposed method was able to clarify the state of oil temperature with a high degree of accuracy.

1. まえがき

制御や冷却にオイルを用いるシステムにおいて、システム内のオイルの特性や状態は、システムの性能に大きな影響を及ぼす。本研究にて対象とする AWD システム⁽¹⁾では、オイルの温度がシステムの出力に影響を与えるため、油温センサにより油温情報を取得し、制御のパラメータとして使用している。AWD システムで用いられるリヤデファレンシャルの構造を Fig. 1 に示す。このシステムは、FF 車をベースとしており、前輪の駆動力を後輪へ伝達し、前後輪間で駆動力を適切に配分することで、2WD と AWD




Fig. 1 Structure of rear differential system

*四輪 R&D センター

の切り替えをおこなう AWD システムである。前輪の駆動力は、プロペラシャフトから入力されたトルクを、クラッチガイドとクラッチハブの間にあるクラッチを締結させることで、ハイポイドギヤ、デファレンシャルギヤを介し両後輪へ伝達される。クラッチの締結力は、アクチュエータ（モータおよびソレノイドバルブ）を用いて油圧を制御し、その発生油圧にてシステム内のクラッチ制御油圧を変化させることで、任意に発生させることができる。システムの動作状態は加圧状態、保持状態、減圧状態の3種類がある。クラッチ制御油圧が必要な場合は、ソレノイドバルブを閉じモータを動作させ加圧をおこない（加圧状態）、制御完了を判断した時点でモータを停止し油圧を保持する（保持状態）といった動作をおこなう。その後、クラッチ制御油圧が不要になると、ソレノイドバルブを開放し減圧をおこなう（減圧状態）。

オイルの粘性が変化すると、クラッチプレート間の油膜のせん断抵抗および摩擦力が変化するため、後輪へ伝達するトルクも変化する。そのため、必要とするクラッチ制御油圧（目標クラッチ制御油圧）を決定するパラメータの一つとして油温センサの値を使用している。油温センサが正常であれば問題ないが、仮に、センサ故障等でセンサ出力値が異常値となると、真の目標クラッチ制御油圧と、各種パラメータから計算により求められる目標クラッチ制御油圧にかい離が発生してしまう。目標クラッチ制御油圧が正しく算出されない状態で走行をおこなうと、車両挙動が不安定になってしまう可能性がある。特に、オイルが低温の時に油温センサの出力値が異常値となってしまうと、リヤデファレンシャル内部のギヤに過大なトルクがかかる可能性があり、ギヤの耐久性に影響を及ぼすことが想定される。そのため、油温センサとは別の手段を用いて、現在の油温が低温か否かを判定する必要がある。

オイルの持つ物理量を得る目的で、さまざまな推定手法や判別手法が提案されているが、その中でも機械学習を用いた手法の有効性が先行研究で示されている。機械学習手法は、モデル化したいデータのみがあればモデル構築が可能のため、対象システムの内部構造を直接知ることが困難な場合でもモデルを構築できるメリットがある。Balabin らは、近赤外分光法により得られた吸収スペクトルデータに対し、k 近傍法 (k-NN) やニューラルネットワーク (ANN)、サポートベクターマシン (SVM) といった識別手法を適用し、エンジンオイルにおける鉱油と合成油の判別や粘度の判別をおこなう手法を提案した⁽²⁾。また、油入変圧器において、変圧器内の絶縁油の温度を、変圧器の負荷および雰囲気温度で学習した ANN を用いて推定する手法については複数の報告⁽³⁾⁻⁽⁵⁾がある。同様に、油入変圧器を対象とした研究では、オイル内のガス成分を特徴量とし、ロジスティック回帰および ANN を用いて、オンロードタッパ切替機の異常状態の判別をおこ

なっている事例⁽⁶⁾がある。この論文では、ロジスティック回帰に比べ ANN の判別精度が良いため、ANN を用いるアプローチの方が有効であると述べられている。

これらの報告では、ANN や SVM を用いることにより、オイルの特性を高精度に推定することが可能であることを示している。ANN や SVM は非線形モデルのため、相関関係が複雑なデータに対しても精度良く推定や判別が可能である。しかし、その反面、結果を出力する際は、数値計算により活性化関数やカーネル関数といった非線形関数を多数計算する必要がある。また、SVM ではサポートベクターのデータをメモリ内にストアしておく必要がある。自動車の制御ではリアルタイム性が重視されることが多く、計算コストやリソースの観点から望ましい手法とはいえない。さらに、これらの手法を適用したとしても、出力された値の信頼性をいかにして判断するかといった課題も存在する。

そこで、本研究では、AWD システムを対象として、計算コストを抑えつつも高精度かつ高い信頼性を有する油温判別手法を構築した。以下に詳細を述べる。

2. 油温判別手法について

2.1. 油温とモータ電流の関係

本手法では、油温とモータ電流の関係に着目し、これらのデータ間における相関をモデル化することで、油温の状態を判別する手法を構築した。本システムの加圧構造は、モータへ通電することでモータ先端に取り付けられたロータが回転し、トロコイドポンプの原理によりオイルを吸い上げる機構となっている (Fig. 2, Fig. 3)。前述のように、オイルの粘性は温度特性を持ち、低温になるほど粘性が高くなるため、ロータが受けるフリクションもこの影響を受けると考えられる。また、モータの特性より、モータへの供給電流と発生トルクの間には線形の関係がある。そのため、加圧時のモータ電流と油温の間にも相関が存在すると考えられる (Fig. 3)。

まず、油温とモータ電流の関係を明らかにするために、




Fig. 2 Schematic of target system

システムが持つパラメータを用いて、これらの関係を定式化する。モータに対する動作指示直後の過渡状態を考慮すると、モータ電流 $I_1(t)$, $I_2(t)$ は以下の式により表される。

$$I_1(t) = \frac{V}{R} \left(1 - e^{-t/\tau_1} \right) \quad (1)$$

$$I_2(t) = \frac{1}{R} \left\{ V + \left[\frac{R}{K_T} Tq(t, temp) + V \right] \times \left[1 - e^{-t/\tau_2} \right] \right\} \quad (2)$$

ここで、

- V : モータ駆動電圧
- R : モータ抵抗
- K_T : モータのトルク定数
- Tq : モータの出力トルク
- τ_1, τ_2 : モータ特性に依存した時定数
- $temp$: 油温
- t : 時間

であるとする。式 (1) および式 (2) の電流波形の概略を Fig. 4 に示す。次に式 (1) および式 (2) を用いて、時刻 $t=0$ から $t=T$ までの電流積算値を計算する。 $t=T_1$ 時の電流はロック電流相当の電流が通電するため、 T_1 は定数とみなすことができ、また積算時間 T を任意の定数とすることで、電流積算値は以下のように表される。




Fig. 3 Cross-section view of motor pump




Fig. 4 Current waveform model

$$\begin{aligned} & \int_{t=0}^T [I_1(t) + I_2(t)] dt \\ &= \frac{V}{R} \left[T_1 + \tau_1 \left(e^{-T/\tau_1} - 1 \right) \right] + \frac{V}{R} (T - T_1) \\ &+ \frac{1}{R} \left[\frac{R}{K_T} \int_{t=0}^{T-T_1} Tq(t, temp) dt - V \right] \left\{ (T - T_1) + \tau_2 \left[e^{-(T-T_1)/\tau_2} - 1 \right] \right\} \quad (3) \\ &= c_1 V + c_2 \int_{t=0}^{T-T_1} Tq(t, temp) dt \end{aligned}$$

ここで c_1 および c_2 は定数である。

さらに式 (3) において、油温がある任意の値の場合を考える。すると、モータ駆動トルクに関する積分項は定数と見なせるため、式 (3) は、

$$\int_{t=0}^T [I_1(t) + I_2(t)] dt - c_1 V = const \quad (4)$$

となる。式 (4) は、電流積算値、モータ駆動電圧および油温の 3 次元データから、油温が同じ値のデータを抽出した場合、そのデータに含まれる電流積算値およびモータ駆動電圧の 2 次元データは線形となることを示している。言い換えると、これは電流積算値とモータ駆動電圧を特徴量とした油温判別モデルを構築する場合、判別の決定境界が線形となることを表している。この事実より、用いる判別モデルは、ANN や SVM といった非線形モデルではなく、より計算コストの低い線形モデルで十分であることがわかる。

2.2. 判別モデルの構築

前述の結果より、本手法ではロジスティック回帰を用いて、電流積算値とモータ駆動電圧を入力し、油温の状態を出力する 2 クラス判別 (油温が低いかな否かを判別する) モデルを構築した。ロジスティック回帰は一般線形化モデルの一つであり、外れ値 (他の値から大きく外れた値) に対し頑健であるという特徴を持つ判別手法である⁽⁷⁾。

ロジスティック回帰のモデルは

$$LOG = \frac{1}{1 + \exp(-\mathbf{w}' \mathbf{x})} \quad (5)$$

と表現される。ここで、

- $\mathbf{x}$: 入力データベクトル
- $\mathbf{w}$: パラメータベクトル
- LOG : クラスの事後確率

であるとする。 $\mathbf{x}$ は電流積算値、モータ駆動電圧の 2 次元ベクトル、 LOG は油温がしきい値以上 (もしくは以下) である確率となる。 $\mathbf{w}$ がモデルの振る舞いを決定するパラメータとなり、これは電流積算値、モータ駆動電圧および油温状態のデータから以下の計算によって求めることが可能である。

まず、各データにおける真の油温状態を t と表現する。判別するクラスが 2 クラスであるため、 $t \in \{0, 1\}$ とすると、

L 個のデータに対する尤度関数は以下の式で表現される。

$$p(\mathbf{t}|\mathbf{w}) = \prod_{i=1}^L \text{LOG}_i^{t_i} \{1 - \text{LOG}_i\}^{1-t_i} \quad (6)$$

ここで、 $\mathbf{t}$ は真の油温状態のベクトル、 LOG_i は $\mathbf{x}_i$ に対する式 (5) の値である。尤度関数の負の対数を誤差関数 $E(\mathbf{w})$ と定義すると、式 (6) より、 $E(\mathbf{w})$ は

$$\begin{aligned} E(\mathbf{w}) &= -\ln p(\mathbf{t}|\mathbf{w}) \\ &= -\sum_{i=1}^L \{t_i \ln \text{LOG}_i + (1-t_i) \ln (1 - \text{LOG}_i)\} \end{aligned} \quad (7)$$

と表現される。式 (7) を最小化する $\mathbf{w}$ が求めたい値であるが、これはニュートン・ラフソン法を用いて、以下の式を繰り返し計算することにより求められる。

$$\mathbf{w}_{s+1} = \mathbf{w}_s - \mathbf{H}^{-1} \nabla E(\mathbf{w}) \quad (8)$$

ここで、 s は繰り返し計算の回数、 $\mathbf{H}$ は $\nabla^2 E(\mathbf{w})$ により求められるヘッセ行列である。式 (5) で定義されるロジスティック回帰モデルの場合、 $\mathbf{H}$ が正定値行列となるため、式 (7) は $\mathbf{w}$ の凸関数となり、大域最適解と局所最適解が一致する。よって、式 (8) に従い計算を繰り返し、収束した $\mathbf{w}$ の値が求めたいパラメータの値となる。 $\mathbf{w}$ を決定したのち、式 (5) に対し、 $\mathbf{x}$ を与え、 LOG がしきい値より上 (もしくは下) かを判定することで、油温判別結果を出力できる。

通常のロジスティック回帰である式 (5) の場合、出力はあるデータが 1 個入力された場合の確率でしかない。そのため、判別のしきい値を低くすると誤判別の可能性が高まり、大きくすると判別がされにくくなるトレードオフが発生する。そこで、複数のデータが入力された場合の確率を計算する手法を導入し、判別精度と判別頻度の両立を可能にした。

まず、式 (5) の拡張として、 $\mathbf{x}_1, \mathbf{x}_2$ の 2 個の入力データが与えられ、両方とも油温が低温であると判別された場合 ($y=1$ と表現) の事後確率を求めることを考える。事後確率 $p(y=1|\mathbf{x}_1, \mathbf{x}_2)$ は、ベイズの定理により、

$$\begin{aligned} p(y=1|\mathbf{x}_1, \mathbf{x}_2) &= \frac{p(\mathbf{x}_1|y=1)p(\mathbf{x}_2|y=1)p(y=1)}{p(\mathbf{x}_1, \mathbf{x}_2)} \end{aligned} \quad (9)$$

と表現できる。同じクラス内でも時間経過により油温が変化することが考えられるため、ここでは $\mathbf{x}_1$ および $\mathbf{x}_2$ に条件付き独立の仮定をおいた。

次に、 $\mathbf{x}_1$ に対するロジスティック回帰の出力を LOG_1 とおき、それをベイズの定理に従い、以下のように変形する。

$$\begin{aligned} \text{LOG}_1 &= p(y=1|\mathbf{x}_1) \\ &= \frac{p(\mathbf{x}_1|y=1)p(y=1)}{p(\mathbf{x}_1)} \end{aligned} \quad (10)$$

同様に、 $\mathbf{x}_2$ に対するロジスティック回帰の出力を LOG_2 とおくと、

$$\text{LOG}_2 = \frac{p(\mathbf{x}_2|y=1)p(y=1)}{p(\mathbf{x}_2)} \quad (11)$$

と表現できる。さらに、式 (10) と式 (11) を用いて、式 (9) を以下のように表すことができる。

$$p(y=1|\mathbf{x}_1, \mathbf{x}_2) = \frac{\text{LOG}_1 \times \text{LOG}_2}{p(y=1)} \frac{p(\mathbf{x}_1)p(\mathbf{x}_2)}{p(\mathbf{x}_1, \mathbf{x}_2)} \quad (12)$$

また、同様の計算により、 $p(y=0|\mathbf{x}_1, \mathbf{x}_2)$ は、

$$\begin{aligned} p(y=0|\mathbf{x}_1, \mathbf{x}_2) &= \frac{(1 - \text{LOG}_1) \times (1 - \text{LOG}_2)}{p(y=0)} \frac{p(\mathbf{x}_1)p(\mathbf{x}_2)}{p(\mathbf{x}_1, \mathbf{x}_2)} \end{aligned} \quad (13)$$

と表すことができる。式 (12) および式 (13) と、 $p(y=1|\mathbf{x}_1, \mathbf{x}_2) + p(y=0|\mathbf{x}_1, \mathbf{x}_2) = 1$ であることより、

$$\begin{aligned} \frac{p(\mathbf{x}_1)p(\mathbf{x}_2)}{p(\mathbf{x}_1, \mathbf{x}_2)} &= \frac{p(y=1)}{\text{LOG}_1 \times \text{LOG}_2 + (1 - \text{LOG}_1) \times (1 - \text{LOG}_2)} \end{aligned} \quad (14)$$

となる。事前確率である $p(y=1)$ および $p(y=0)$ に関する情報は得られないため、ここでは $p(y=1) = p(y=0)$ とした。式 (14) を式 (12) に代入することで、 $\mathbf{x}_1, \mathbf{x}_2$ が与えられた場合の事後確率は、以下の式で表すことができる。

$$\begin{aligned} p(y=1|\mathbf{x}_1, \mathbf{x}_2) &= \frac{\text{LOG}_1 \times \text{LOG}_2}{\text{LOG}_1 \times \text{LOG}_2 + (1 - \text{LOG}_1) \times (1 - \text{LOG}_2)} \end{aligned} \quad (15)$$

また、同様の計算をおこなうことで、 n 個のデータ ($\mathbf{x}_1, \dots, \mathbf{x}_n$) が入力された場合の事後確率は、

$$\begin{aligned} p(y=1|\mathbf{x}_1, \dots, \mathbf{x}_n) &= \frac{\prod_{i=1}^n \text{LOG}_i}{\prod_{i=1}^n \text{LOG}_i + \prod_{i=1}^n (1 - \text{LOG}_i)} \end{aligned} \quad (16)$$

と表現できる。

式 (16) に対するしきい値として、ロジスティック回帰に対する判別しきい値よりも高いしきい値を導入し、式 (16) の判別結果を最終的な判別結果とする。これにより、信頼度の高い入力がおこなわれた場合は即時的に確定をおこない、通常レベルの信頼度の入力が連続でおこなわれた場合も確定が可能なアルゴリズムが、ロジスティック回帰モデルの出力のみで実現可能となる。式 (16) に従い、データが追加されるたびに事後確率が増加する様子を Fig. 5 に示す。Fig. 5 は、ロジスティック回帰に対する判別しきい値以上となる入力が連続でおこなわれた場合の




Fig. 5 Example of transition of posterior probability




Fig. 6 Algorithm of proposed method

例を表しており、事後確率が高いしきい値を上回った場合に判別結果の確定をおこなう。アルゴリズムの全体フローを Fig. 6 に示す。

3. 実験結果

実際にシステムより得られたデータを用いて、油温がしきい値以上かを判別するモデルを作成し、判別率の評価をおこなった。モデル構築および評価は、電流積算値、モータ駆動電圧、油温状態の3次元データを用い、10-fold クロスバリデーション（データ群を10個に分割し、その内の9個をモデル構築に使用、残り1個をモデルの性能評価に使用する。これを10回繰り返す。なお、前半の9個のデータを訓練データ、後半の1個のデータをテストデータと呼ぶ。）により実施した。また、電流積算時間は150 msとした。ロジスティック回帰モデルによる判別結果を Table 1 に示す。Table 1 において、Training の列は訓練データに対する判別率を示し、Test の列はテストデータに対する判別率を示している。また、それぞれの列において、Mean の列はクロスバリデーションにより得られた判別率の平均値を、Min の列は最も低い判別率となった値を示している。

まず、訓練データに対する結果より、線形モデルでも、油温の状態を高精度に判別可能であることがわかる。本システムにおいては、特に、低温で高い判別精度が求められるが、低温ほど、より高精度の判別がおこなわれており、システム要求にかなった結果となっている。これは、低温になるほど、油温に対するオイル粘性の変化が大きく、しきい値付近のデータに対する判別率が向上するためであると考えられる。

また、テストデータに対しても、温度帯によらず、訓練データと比べて遜色ない判別率を得ることができた。これは、生成されたモデルの汎化能力が高いことを示しており、未知の新たなデータに対しても正しく判別をおこなうことが可能なモデルが構築できていることがわかる。ロジスティック回帰モデルの出力に対し、さらに式 (16) のアルゴリズムを組み合わせることで、より高精度な判別を実施することが可能である。

次に、本判別問題に対する判別モデルを、ロジスティック回帰、ANN、および SVM で構築し、3000 個のデータに対し判別計算を実行した場合の計算時間を測定した。結果を Table 2 に示す。測定において ANN と SVM は、判別精度を保ちつつ、計算コストが低くなる非線形モデルを選択した。特に、ANN については、一般化線形モデルとの差を表現する目的で、2 個の隠れユニットを持つ 2 層ネットワーク（入力 2 個、隠れユニット 2 個、出力 1 個）を用いて評価をおこなった。この結果より、判別モデルとしてロジスティック回帰を選択することで、ANN と SVM を選択した場合に比べ、計算コストを削減できることがわかる。

Table 1 Classification rate of logistic regression

Threshold (°C)	Training		Test	
	Mean	Min	Mean	Min
20	0.974	0.973	0.973	0.960
10	0.985	0.984	0.985	0.982
0	0.982	0.982	0.982	0.977
-10	1.000	1.000	0.999	0.999
-20	0.999	0.999	0.999	0.997
-30	0.996	0.995	0.996	0.992

Table 2 Computing time comparison

Logistic regression	ANN	SVM
0.14 ms	0.23 ms	0.41 ms

4. まとめ

対象とする電子制御 AWD システムにおいて、システム内部の油温状態を判別する手法を構築し、その効果を確認した。その際、モータの電流波形を定式化し、油温を固定値とした場合の電流積算値とモータ駆動電圧の関係がデータ空間において線形になることを求めることで、目的に対し必要十分な機能を持つ判別手法を選択し、計算コストの抑制を実現した。また、複数回の判別結果の信頼性を定量的に評価し、最終的な判別結果を出力するアルゴリズムを判別モデルの出力のみを用いて構築することで、計算コストを抑えつつ、最終的な判別結果の信頼性と判別頻度を両立させる手法を実現した。

参考文献

- (1) 山口暢隆, 原次郎: 軽量低フリクション電子制御 4WD システムの開発, 自動車技術会 学術講演会前刷集, No.146-12, p.19-23(2012)
- (2) Balabin, R. M., Safieva, R. Z., Lomakina, E. I.: Near-infrared (NIR) spectroscopy for motor oil classification: From discriminant analysis to support vector machines, Microchemical Journal, Vol. 98, p.121-128(2011)
- (3) Pradhan, M. K., Ramu, T. S.: On-line Monitoring of Temperature in Power Transformers using Optimal Linear Combination of ANNs, Conference Record of the 2004 IEEE International Symposium on Electrical Insulation, p.70-73(2004)
- (4) Tang, W. H., Zeng, H., Nuttall, K. I., Richardson, Z., Simonson, E., Wu, Q. H.: Development of Power Transformer Thermal Models for Oil Temperature Prediction, Real-World Applications of Evolutionary Computing, EvoWorkshops 2000, Lecture Notes in

Computer Science, Vol. 1803, p.195-204(2000)

- (5) He, Q., Si, J., Tylavsky, D. J.: Prediction of Top-Oil Temperature for Transformers Using Neural Networks, IEEE Transactions on Power Delivery, Vol. 15, No. 4, p.1205-1211(2000)
- (6) Wang, H., Liu, Y., Griffin, P. J.: Artificial Intelligence in OLTC Fault Diagnosis Using Dissolved Gas-In-Oil Information, Power Engineering Society Summer Meeting, Vol. 4, p.2422-2427(2000)
- (7) C.M. ビショップ, 元田浩, 栗田多喜夫, 樋口知之, 松本裕治, 村田昇: パターン認識と機械学習 ベイズ理論による統計的予測, シュプリンガー・ジャパン株式会社, p.177-208(2008)

■ 著 者 ■



吉野 弘規