

# 鉛バッテリー状態検知センサ

～等価回路モデル学習と Support Vector Machine によるバッテリー種類識別技術開発～

## Battery State Sensor

～ Development of Battery Type Classification Technology  
by Using Equivalent-circuit Model and Support Vector Machine ～

岩根 典靖<sup>\*1</sup>  
Noriyasu Iwane

光山 泰司<sup>\*1</sup>  
Taiji Mitsuyama

谷村 雄大<sup>\*2</sup>  
Yudai Tanimura

### 〈概要〉

近年鉛バッテリー状態検知センサ搭載車両が増加中である。唯一の日系サプライヤである当社はカーメーカーからの各種技術的要求に応えながらシェアの拡大に取り組んでいる。

鉛バッテリー状態検知センサ搭載車両の増加の背景には車両電源システムに対するさらなる信頼性向上への要求がある。一方バッテリー自体に関してもアイドリングストップシステム搭載車両で求められる苛酷な使用環境に耐える専用バッテリーが開発されるなどバリエーションが増えている。これらの動向の一環としてカーメーカーより通常液式とアイドリングストップ車専用タイプとを識別する技術の開発が期待されている。当社はこれまで開発してきたバッテリー等価回路モデル学習技術と、現在知られている識別ツールの中で最も強力と言われている Support Vector Machine の併用により通常液式とアイドリングストップ車専用タイプを識別する技術を開発し、試行の結果十分な実用の可能性を確認できた。

## 1. はじめに

昨今のアイドリングストップシステム搭載車両（アイドリングストップ車）の一般化や電装部品の数量、重要性の増大により車両電源の信頼性が重要となってきた。これに伴い電流、電圧、温度などの直接的計測値に加えバッテリーの充電率、劣化状態等を検知する高機能な鉛バッテリー状態検知センサの車両搭載が急速に進みつつある。当社はこの鉛バッテリー状態検知センサの唯一の日系サプライヤとして Battery State Sensor (BSS) を上市し、積極的な新機能開発を進めることによって今後のシェア拡大を目指している。図1にBSSの製品例を示す。

上記車両電源頑健性への要求に関連してバッテリー自体に関してもアイドリングストップ車両に特化した専用バッテリーなどバリエーションが増えている。カーメーカーはそれらのバリエーションに対して最も適した制御を使い分けることが理想であると考えており、当社BSSにはこれらを識別する機能・技術の実装が期待されている。

我々はこれまで開発したバッテリー等価回路モデルの車載環境での学習技術と現在知られている最も強力な識別ツールである Support vector machine (SVM)<sup>1)</sup> を併用して通常液式とアイドリングストップ車専用タイプとを識別する技術の開発を試

み、実験室レベルの検証において実用の可能性のある結果を得ることができたのでその内容を報告する。




図1 バッテリー状態検知センサ (古河 AS 製)  
Battery state sensor (made by FAS).

## 2. バッテリー等価回路モデル

充電率、劣化状態等の状態検知と同様バッテリーの種類を識別するためには記述子と呼ばれる指標を設定する必要がある。バッテリーにおいて最も直感的に想起される記述子としては内部抵抗が挙げられるが、単純な一次元の内部抵抗の情報だけではバッテリーサイズなどの影響が重畳するため種類を識別するには実用的な記述子とはならない。したがって多面的な指標すなわ

<sup>\*1</sup> 研究開発本部 自動車・エレクトロニクス研究所

<sup>\*2</sup> 研究開発本部 先端技術研究所

ち多次元の情報が必要である。

このため我々はバッテリー状態を高精度に検知できるように多次元の情報を持つバッテリーの等価回路モデルを導入している。下記図2に代表的なバッテリーの等価回路モデルを示す。




図2 バッテリー等価回路モデル例  
Example of an equivalent circuit model of a battery.

バッテリーに限らず電気化学現象を等価回路モデルで表現する手法は従来から一般に用いられてきている技術である。この手法を用いるメリットは電気化学反応における各構成要素の寄与を非破壊かつ定量的に知ることができる点である。図2はモデルとしてシンプルな例を示しているが、導電抵抗・液抵抗などの純オーミックな抵抗と正極・負極それぞれの電気化学反応による抵抗及び正極・負極それぞれの表面に形成される電気二重層容量で構成されている。またこれらに加えて電解液の濃度拡散による抵抗を加えたモデルも一般的に良く用いられる。

等価回路モデルを用いる一般的な手法では、電気化学インピーダンス法 (Electrochemical Impedance Spectroscopy) <sup>2)</sup> によって設定した等価回路モデルの各要素 (パラメータ) を定量化するのが一般的である。この電気化学インピーダンス法ではまず専用のインピーダンス測定器を用いてバッテリーに交流電流を付加し、交流電流の周波数をスイープさせ、インピーダンスのスペクトルを求め、これを複素平面上にプロットしたNyquist-plotと呼ばれる形で表現し、このNyquist-plotの挙動が最も良く再現するように等価回路モデルのパラメータを決定するという手法である。図3にNyquist-plotの例を示す。




図3 鉛バッテリーのNyquist-plot例  
Example of a Nyquist-plot of a lead-acid battery.

このようにして定量化された等価回路モデルのパラメータが実際の現象を良く説明できることからバッテリーに限らず電気化学の分野で現在広く用いられている。

一方BSSでは車載環境にて定期的にバッテリーの等価回路モデルのパラメータを学習・更新していく必要がある。この場合には交流正弦波信号の生成を必要とするインピーダンス測定器を用いた学習は不可能である。そこで我々はBSSに実行可能な技術として実車環境の動的な電流電圧応答から同様の等価回路モデルパラメータの学習・定量化を行う技術の開発を進めてきた<sup>3)</sup>。その概要はBSSからの定期的なパルス放電によるパルス電流に対する電圧応答 (図4) 及びエンジン始動時の電流電圧応答 (図5) の動的な挙動をサンプリングし、等価回路モデルによるシミュレーション計算がサンプリングと最も良く一致するように等価回路モデルのパラメータを最適化する考えである。




図4 パルス放電電流電圧波形例  
Example of the wave shape of a pulse discharge current and voltage.




図5 始動電流電圧波形例  
Example of a wave shape of a cranking current and voltage.

前述の通り実車環境での等価回路モデルの最適化技術と等価回路モデルの多次元の記述子を活用した高精度な状態検知の実現を目指してきた。本技術の命題はバッテリー種類を識別することであるが、等価回路モデルはバッテリーの状態・特性を示すものであるため特性に差のあるバッテリー種類を識別する上でも有効な記述子として機能することが期待できる。

### 3. Support vector machine (SVM)

2種以上のグループからなるサンプル群から得た記述子が混在しているデータを基にそれぞれの記述子がどのグループに属するものであるのかを特定する命題は識別問題と呼ばれ、広い分野で取り扱われる課題である。この識別問題を解くツールとして最も良く知られているのは Artificial neural network (ANN)<sup>4)</sup> であるが、これを拡張した Convolutional neural network (CNN)<sup>5)</sup> は特に画像認識において高い識別能力を持つことが知られており、車載用途においては自動運転技術への応用などが期待されている。一般に識別問題を解くツールを活用するためには事前に各グループへの帰属が既知である記述子群の例を教師データとして準備し、ツールの学習を完了させておく必要がある。特に精度の高い識別を実現するためにはネットワークの設計の手間以外に膨大な数の教師データを集め、膨大な演算負荷をかけて学習を行う必要があり、これが ANN の弱点になっている。更に分離超平面と呼ばれる識別の境界の解は一般には無限に存在するため学習した結果が大局的最適解に至らず、局所的最適解に陥るリスクも有る。

この点を克服したツールとして SVM が脚光を集めている。SVM の詳細に関しては数多くの解説<sup>6),7)</sup> があるためここでは概要のみを簡単に述べる。ANN が人間のニューロン細胞の動作を模擬したツールであるのとは異なり SVM は純粋に数学的・幾何学的なツールである。その基本思想を下記図6に示す。




図6 Support vector machine の基本概念  
Basic concept of a Support vector machine.

図6にはシンプルな2次元の記述子から成る識別空間を示しているが、SVM の特徴は分離超平面に対して最も近いデータ群 (Support vector) のみに着目し、分離超平面と Support vector との法線距離 (マージン) が最大となるように分離超平面を決定するものである。これにより取り扱うデータの大幅な削減と一意な大局的最適解の決定が実現され、その結果未学習の識別対象データに対しても高い識別性能 (高い汎化性能) を有するツールとなっている。我々の用途においても高い汎化性能は最も重要な特性の一つとなる。

上記の美点を持つ一方、発明の時点では線形識別器であったため世の中の多くの非線形識別では対応困難であった。この点で非線形識別器である ANN に劣っており、適用が限られてい

たが Kernel-trick と呼ばれる手法が考案され、SVM の適用が一気に広がった。Kernel-trick の基本的な考えは仮想的な次元を追加した特徴空間と呼ばれる空間へデータを写像し、この特徴空間の中において線形分離可能な平面を決定するというものである。特徴空間への写像のイメージを下記図7に示す。




図7 特徴空間への写像のイメージ  
Image of a feature space mapping.

一般に多次元化された空間への写像を行うためには各データの特徴空間中での座標を求める必要があり、「特徴空間の次元×データ数」の座標計算が必要となる。また元の記述子の次元が高ければ個々の計算も複雑となり、多くの場合膨大な計算が必要となる。

Kernel-trick の特徴は付加する仮想次元の座標を求める Kernel 関数を適切に選定することによって特徴空間の座標計算を関数の定数の算出に置き換え、これによって大幅に演算負荷を減らすものである。Kernel-trick を成立させる代表的な Kernel 関数としては Gaussian-kernel, Laplace-kernel, 多項式 kernel などが知られている。

### 4. 識別対象とするバッテリー群

前述の通り近年アイドリングストップ車が一般的となっている。アイドリングストップ車には非アイドリング・ストップ車に搭載されてきた従来の液式鉛バッテリーではなく、アイドリングストップ車専用に設計されたバッテリーが搭載されている。これは車両のアイドリングストップ動作に対応した頻繁なエンジン (発電機) の停止と再始動の繰り返しへの耐性、高い

回生受入性と中間充電状態での保持に対する耐性等バッテリーとして過酷な使用環境に対応できる設計となっている。このため従来の液式鉛バッテリーがアイドリングストップ車で使用された場合には急速なバッテリーの劣化が発生し、場合によっては走行中の電源失陥から事故に繋がるケースも想定される。

上記はバッテリー識別が求められるケースの1例であるが、今回はこのケースを想定して識別の可能性を検討する。表1に代表的なアイドリングストップ車専用バッテリーと従来の液式バッテリーの対応表を示す。

**表1** アイドリングストップ車専用バッテリーと従型液式バッテリーの対応表  
Comparison Table of between Typical Batteries Exclusive for Mild Hybrid Vehicles and Traditional Lead-Acid Batteries.


Normal Type	For Start-stop vehicle	External dimensions (Max.) / mm			
		Length	Width	Container height	Overall height
B20	M-42	197	129	204	227
B24	N-55	238	129	204	227
D23	Q-85	232	173	204	225
D26	S-95	260	173	204	225
D31	T-110	306	173	204	225

今回の検討においては、日系4メーカー及びのバッテリーから下記表2に示す計27種類のバッテリー(計184ヶ)を教師データとして用いた。

**表2** 教師データとして選定したバッテリー群  
Batteries used as training data.

Maker	Battery type	Size
Maker A	Normal type	38B19 44B19 55B24 110D26
	For Start-stop vehicle	M-42 Q-85
Maker B	Normal type	46B24 80B24 55D23
	For Start-stop vehicle	M-42 N-55 Q-55 Q-85
Maker C	Normal type	40B19 55D23 80D23 80D26 115D26
	For Start-stop vehicle	M-42 N-55 Q-85 S-95
Maker D	Normal type	80D26 110D26
	For Start-stop vehicle	M-42 Q-85 S-95

記述子は前記の通り等価回路モデルのパラメータであるが、今回の検討では図2に示すモデルと同一のモデルを想定した。モデルのパラメータを求める手法は当社開発のロジックを用い、前記モデルパラメータのうち  $Rohm$ ,  $Rct1$ ,  $C1$  の3つの成分を、パルス放電時の電流電圧応答から学習させることとした。学習にはパルス放電機能及び当社開発ロジックを実装したプロトタイプセンサを用いた。当社は等価回路モデルの温度とSOCによる影響を排除するロジックを構築しているが、今回の検討では実現の可能性の検討に主眼を置き、全てのバッテリーをMax電流=10時間率電流, 14.4 V保持のCV充電にてSOC=100%に調整し、温度環境を25℃に固定して温度とSOCに影響されることのない理想条件で学習を行った。得られた等価回路モデル(3つの記述子)の3次元分布図を図8に示す。



**図8** 等価回路モデルの3次元分布図  
3-Dimensional distribution diagram of the equivalent circuit model.

### 5. 識別の試行と結果

センサが識別を行うに当っては予め作成済みの分離超平面さえ実装しておけば学習した等価回路モデルと分離超平面の比較によりバッテリー種類の識別を行うことができる。従って特段分離超平面策定のための識別器の開発を行う必要は無く、市販の識別器を活用すれば良い。今回我々はMathworks社の汎用数値解析ソフトウェア Matlab (R2014a) のオプションで準備されている Statistics Toolbox の SVM 機能 (svmtrain 関数) を活用した。

分離超平面の学習に当っては、前記表2の日系4メーカーの通常液式およびアイドリングストップ車専用のバッテリー合計27種の等価回路モデル ( $Rohm$ ,  $Rct1$ ,  $C1$ ) のデータを教師データとして準備し、svmtrain 関数コマンドを実行することによって結果を出力させることができる。当然最もシンプルな試行としては27種のバッテリーを直接2グループに分けて1つの分離超平面で識別し切る方法であるが、事前のデータ確認においてこの方法では精度の高い識別は困難であることが予想された。その例を下記表3に示す。

表3 等価回路モデルパラメータ例  
Example of equivalent circuit model parameters.

Width / mm	Type	Size	Maker	Rohm / Ω	Rct1 / Ω	C1 / F
129	Normal type	46B24	Maker C	0.00807	0.00310	2.255
		55B24	Maker A	0.00682	0.00386	1.700
	For Start-stop vehicle	M-42	Maker B	0.00648	0.00226	2.543
		N-55	Maker C	0.00559	0.00292	2.573
173	Normal type	80D23	Maker B	0.00593	0.00268	2.856
		80D23	Maker D	0.00600	0.00320	2.150
	For Start-stop vehicle	Q-85	Maker B	0.00466	0.00153	2.890
		S-95	Maker D	0.00342	0.00164	4.111

一般にバッテリーは容量の大きなバッテリーほど内部抵抗が小さく、電気二重層容量は大きくなる傾向がある。我々はこの傾向をバッテリー状態検知に利用しているのであるが、アイドリングストップ車専用バッテリーは前述の様なアイドリングストップ車の制御に耐えるため通常液式の同一電槽サイズのバッテリーより内部抵抗が小さく、電気二重層容量の値が大きくなる設計となっている。その結果として幅129 mm (通常液式Bサイズ)のアイドリングストップ車専用バッテリーは、幅173 mm (通常液式Dサイズ)の80D23と近い値となっている。しかもその値は3つのモデルパラメータ全てで値に重なりを持っており、多次元空間に写像しても実用的な識別は困難であろうと推測された。一方で幅129 mm (通常液式Bサイズ)と幅173 mm (通常液式Dサイズ)では幅寸法が異なるため同一車両でこれらが跨って使用されることはまず無いと考えられる。従って1つのセンサは幅129 mmと幅173 mmのいずれか一方のバッテリー群だけを対象として識別出来れば良いと割り切った考えは成立し得る。今回の検討では実現の可能性の検討という観点からこの考えに従うこととした。

以上の考えで図8の等価回路モデルパラメータを2つのグループに分けて教師データを作成した。前述の通りKernel-trickによる特徴空間への写像を行うに当っては適切なKernel関数を選定する必要がある。MatlabのStatistics Toolboxには予め定まったKernel関数が実装されているが、Kernel関数の形状は特徴空間への写像へも反映される。今回図8における3次元の記述子空間内でのデータの分布状態から多項式kernelが最も適していると考え、多項式kernelを主体に検討した。多項式の次数は任意に設定可能であるが、次数が高いほどより高次の特徴空間への写像となる。元の3次元の記述子空間から多項式kernelによる写像を行った場合、n次kernelでは $(3+n)C_n-1$ 次元への写像になる。従って1次kernelで3次元、2次kernelで9次元、3次kernelで19次元となる。一般に次数を上げるほど誤識別を減らすことができ、数学的には含まれるデータの数まで次元を上げればどんな物でも線形識別が可能であることが証明されているが、一方で次元を上げれば逆に汎化性能が低下することも知られている。そこで今回多項式kernelの次数を水準に何処まで次数を上げれば誤識別ゼロとすることができるかを試行し、結果3次kernelによって幅127 mm, 幅173 mmの両グループとも誤識別ゼロを実現することに成功した。

幅173 mmグループを例に分離超平面による識別結果を図9に示す。3次kernelによって多次元化された空間で作成した分

離超平面を元の3次元の記述子空間では下記(1)式の3次曲面関数として表される。

$$\begin{aligned}
 &A0 + A1 \cdot Rohm^3 + A2 \cdot Rct1^3 + A3 \cdot C1^3 \\
 &+ A4 \cdot Rohm^2 \cdot Rct1 + A5 \cdot Rohm^2 \cdot C1 \\
 &+ A6 \cdot Rohm \cdot Rct1^2 + A7 \cdot Rohm \cdot C1^2 \\
 &+ A8 \cdot Rct1^2 \cdot C1 + A9 \cdot Rct1 \cdot C1^2 \\
 &+ A10 \cdot Rohm \cdot Rct1 \cdot C1 \\
 &+ A11 \cdot Rohm^2 + A12 \cdot Rct1^2 + A13 \cdot C1^2 \\
 &+ A14 \cdot Rohm \cdot Rct1 + A15 \cdot Rohm \cdot C1 \\
 &+ A16 \cdot Rct1 \cdot C1 + A17 \cdot Rohm + A18 \cdot Rct1 \\
 &+ A19 \cdot C1 = 0
 \end{aligned}
 \tag{1}$$

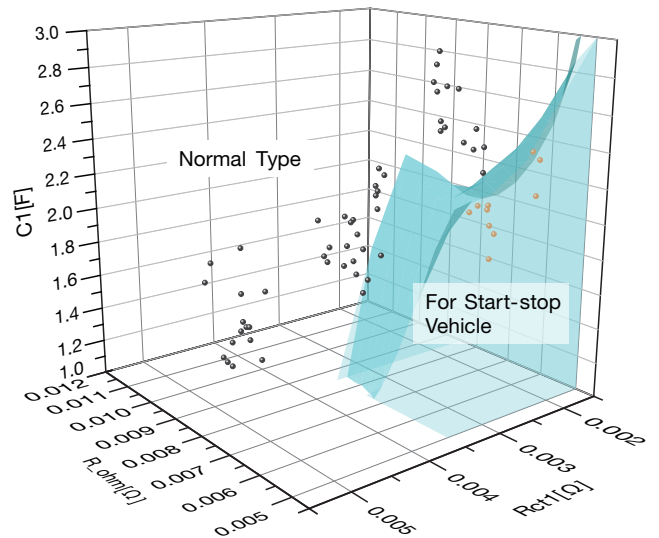


図9 幅173 mmグループの識別結果例  
Example of the Result of the Identification (width 173 mm group).

## 6. おわりに

今回の試行においてこれまで開発してきたバッテリー等価回路モデル学習技術とSVMの併用により、準備した教師データに対して誤識別ゼロという実用が期待できる結果が得られた。一般に識別問題の精度検証においてはCross-validation-testが行われるが、準備できた教師データ数が十分でなかったために今回は行っていない。バッテリーメーカーはカーメーカーより提示

される要求を満たせるようにバッテリーの設計を行っているので、図9のように3次元記述子空間内で通常液式とアイドリングストップ車専用のバッテリーの記述子が分離超平面の両側に分離されていることが分かる。今回教師データとして選定したバッテリー以外のバッテリーに関してもこの傾向が大きく崩れることは無く一定以上の識別性能が維持できると期待できるが、教師データ数に対して特徴空間の次元が十分低いとは言えない状況であり、汎化性能の検証が今後の最大の課題と言える。また今回の等価回路モデルは温度とSOC条件を固定した理想的な条件で等価回路モデルの学習を行ったが、実用化に対しては実車環境で発生する様々な誤差、ばらつきを吸収し得る識別性能を確保できることが求められる。この点も今後の検証課題と考える。

今回の検討では分離超平面の性能に大きく影響を与えるKernel関数に関しては主に多項式kernelを主体に検討を行ったのみで深く踏み込む検討は行っていない。Gaussian-kernelなどGauss関数の形状から今回の我々の記述子データに対して明らかに適当でないと判断できるケースも多いが、準備されている全てのKernel関数に関してその基本形状の確認までは行っていない。またツールに準備されていないKernel関数の模索を行うことでより高い識別を実現できる可能性もある。これらの課題を検討することで今後の更なる性能改善が期待できる。

### 参考文献

- 1) V.N.Vapnik: The Nature of Statistical Learning Theory, Springer, Berlin (1995).
- 2) 板垣昌幸: 電気化学インピーダンス, 丸善出版 (2011).
- 3) 岩根典靖, 高嶋直也, 光山泰司: 動的電流電圧からの鉛バッテリー等価回路モデル学習とこれを用いた応答電圧予測, 2013年度電気化学会秋大会.
- 4) 岩田彰・松原俊之: ニューラルネットワーク入門, <http://mars.elcom.nitech.ac.jp/java-cai/neuro> (1996).
- 5) Y.LeCun, B.Boser, J.S.Denker, D.Henderson, R.E.Howard, W.Hubbard, L.D.Jackel: Backpropagation applied to handwritten zip code recognition, NeuralComputation, vol.1 pp.541-551 (1989).
- 6) N. Cristianini, J. Shawe-Taylor, 大北剛 (訳): サポートベクターマシン入門, 共立出版 (2005).
- 7) 小野田崇: 知の科学-サポートベクターマシン, オーム社 (2007).
- 8) 福水健次: カーネル法入門, 朝倉書店 (2010).