

新しい体内埋め込み型除細動器のための致死的不整脈検出アルゴリズムの開発

吉澤 誠¹⁾, 木下 広幸²⁾, 山本 佳奈子²⁾, 清水 一夫³⁾,
稻垣 正司⁴⁾, 上村 和紀⁴⁾, 杉町 勝⁴⁾, 砂川 賢二⁵⁾



- 1)情報シナジー機構 情報シナジーセンター 先端情報技術研究部 教授
2)工学研究科 電気・通信工学専攻
3)オリンパス株式会社
4)国立循環器病センター研究所
5)九州大学 医学研究院
E-mail: yoshizawa@isc.tohoku.ac.jp

1. はじめに

埋め込み型除細動器（Implantable cardioverter-defibrillators; ICD）は、心室細動（ventricular fibrillation; VF）や心室頻拍（ventricular tachycardia; VT）などの致死性不整脈を検出して自動的に除細動を行うものである。2001年末で全米では ICD 植え込み例が 8 万件を超えたのに対し、日本では ICD 手術認定施設が 241 施設しかなく、年間手術も 4000 件程度とまだ少ない[1]。問題なのは、ICD は 100% 輸入品であり、ほぼ 2 社で国内のシェアを 2 分していることである。

そこで、国産の ICD を作るために、国立循環器病センターを中心とする研究グループは、厚生労働省の科学研究費補助金による「植込み型突然死防止装置の開発」を平成 15 年度から開始した。この研究グループにおいて、著者らは致死性不整脈の早期検出アルゴリズムの開発を担当している。

従来の ICD は、VF や VT などの検出を主として心電図情報に基づいて行っている[2-6]。心電図の間隔情報を処理する方法では、VF と VT を確実に区別することが困難である。また、植込み対象患者に応じて不整脈検出用パラメータの設定値を変える必要もある。

これに対して、本プロジェクトで開発中の ICD では、心内心電図に加え、コンダクタンス・カテーテルと同様の原理に基づいた心室容積信号の計測が可能となる。これらの情報を組み合わせることにより、より早期にかつ正確に致死性不整脈の発生が検出できる可能性がある。

本報告では、心内心電図信号と心室容積信号の瞬時波形に基づく、自己組織化マップ（self organizing map; SOM）[7]を利用した新しい致死性不整脈検出アルゴリズムを紹介するとともに、計

算量の低減化、シングルチップ・マイクロコンピュータ（以下、マイコン）への実装化、および、実装化したシステムの動物実験による有効性の評価について述べる。

2. 方法

2. 1 自己組織化マップ (SOM) の概要

2. 1. 1 SOM の構造と学習アルゴリズム

教師なしで入力ベクトルの自動分類を行うことが可能な SOM の学習アルゴリズムは次のとおりである[8]。

図 1 のように、SOM は複数のニューロンが平面上に並んで構成されており、 i 番目のニューロンが重みベクトル $w_i(t)$ を持つ。初期状態では $w_i(t)$ はランダムなベクトルである。 $x(t)$ を分類対象の入力ベクトルとするとき、

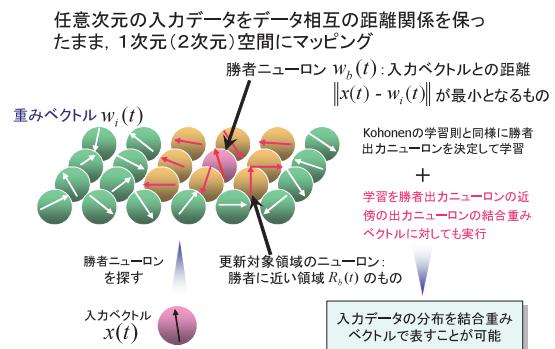


図 1. 自己組織化マップ(SOM)の学習アルゴリズム

$$b = \arg \min_i \|x(t) - w_i(t)\|$$

に従って勝者ニューロンの番号 b を決定する。つぎに、

$$w_i(t+1) = \begin{cases} w_i(t) + \alpha(t)[x(t) - w_i(t)] & \text{if } i \in R_b(t) \\ w_i(t) & \text{if } i \notin R_b(t) \end{cases}$$

に従って $w_i(t)$ を更新する。ここで、 $\alpha(t)$ は時間とともに減少する更新ゲインである。近傍関数 $R_b(t)$ は勝者ニューロン $w_b(t)$ の周りの更新対象領域であり、これも時間とともにその範囲が縮小していく。

本研究では、SOM として 6 角形格子状の二次元マップを用いた。近傍関数 $R_b(t)$ としてガウス型関数を用いた。初期の近傍半径は 4 とし、最終の近傍半径は 1 とした。学習回数は 600 回とした。

学習が進行すると、互いに似た特徴をもつ入力ベクトルは互いに近い重みベクトルを持つ距離的に近いニューロンに投射され、互いに異なる特徴をもつ入力ベクトルは互いに異なる重みベクトルを持つ距離的に遠いニューロンに投射されるようになる。その結果、ニューロンの空間的配置が入力ベクトルの分類結果に対応することになる。

SOM は教師なし学習が可能な競合学習型ニューラルネットワークであり、勝者ニューロンの近傍ニューロンも学習する。これは、トポロジー自己形成ができるこことを意味し、入力データの類似度に応じて分類する能力を自律的に獲得することができる。すなわち、非線形多次元データを、空間の位相的順序を保持したまま低次元に写像することができます。

2. 1. 2 SOMへの入力ベクトル

イヌの右心室内に留置した心電電極とコンダクタンス・カテーテルでそれぞれ計測した心電図(ECG)信号と容積信号を、6 次 Butterworth 型デジタルフィルタによって構成された帯域通過フィルタ(0.5~40Hz)と低域通過フィルタ(~40Hz)に通した。ECG は平均 0・分散 1 に規格化した。また、容積信号は最大値 1・最小値 0 に規格化した。

ECG の R 波を閾値を使って検出し、図 2 のように、R 波の位置と Q 波の位置を求め、1 拍(心周期)を抽出した。

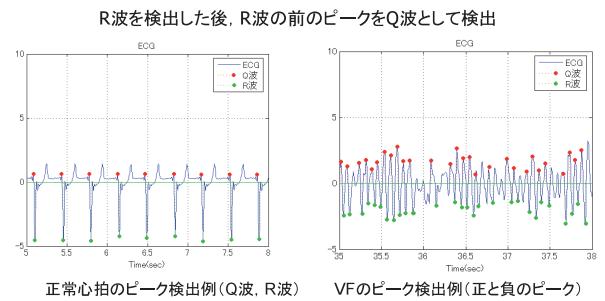


図 2. R 波と Q 波の検出

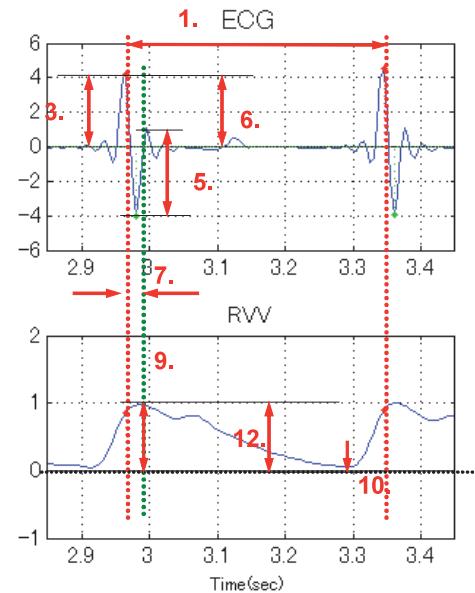


図 3. 入力ベクトルの各要素

1 拍毎に、図 3 に対応する次の 15 の変量を SOM への入力ベクトルの要素とした。

- 1)心拍数
- 2)心拍数 (過去 5 拍の標準偏差)
- 3)Q 波振幅値
- 4)Q 波振幅値 (過去 5 拍の標準偏差)
- 5)R 波振幅値
- 6)R 波振幅値 (過去 5 拍の標準偏差)
- 7)Q-R 間隔 RR 間隔
- 8)ECG 最大値 (過去 5 拍の標準偏差)
- 9)容積最大値
- 10)容積最大値時刻
- 11)容積最小値
- 12)容積最小値時刻
- 13)容積最大値 (過去 5 拍の標準偏差)
- 14)容積最小値 (過去 5 拍の標準偏差)
- 15)容積最大値 - 最小値

2. 1. 3 SOM 上のニューロンのラベリングと領域クラスタリング

学習後の SOM を用いてデータの分類を行うために、図 4 のように、SOM の各ニューロンに対するラベル付けを以下の手順で行う。

- 1) 各学習データにパターンの種類 (VF, VT, Shock, Other) をラベリング
- 2) 学習後の SOM に学習データを再提示し、各学習データに最整合となるニューロンを算出
- 3) 最整合ニューロンのラベルとして、最整合となる学習データのラベルを割り当てる
- 4) 複数の最整合学習データが存在するときはすべてのラベルを採用して保持
- 5) 学習後の SOM の領域を、後述する k-means 法または k-NN 法を用いてクラスタリング
- 6) 各クラスタ内のすべてのニューロンのラベルを、クラスタ内に分布するラベル付けされた最整合ニューロンの多数決により決定

k-means 法のアルゴリズムとは次のようなものである。

- 1) クラスタの代表値の初期値として K 個の種 (シード) をデータ空間中に配置し、各データとシード間の距離を計算
- 2) 各データを最も近いシードのクラスタに所属させ、シードを各クラスタに所属するデータの重心に更新
- 3) 各データを最も近い重心、すなわち 2)で更新した値のクラスタに所属させ、重心を新しいクラスタに所属するデータの重心に更新
- 4) 2)~3)を重心の更新がされなくなるまで繰り返す

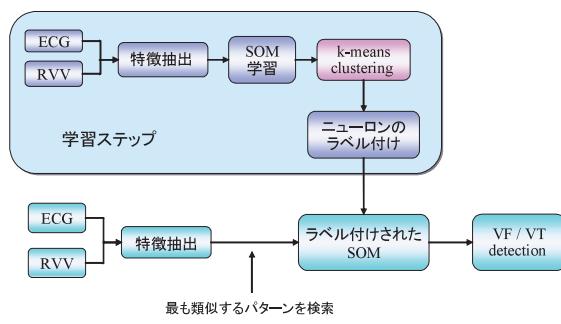


図 4. 入力ベクトルの分類の過程

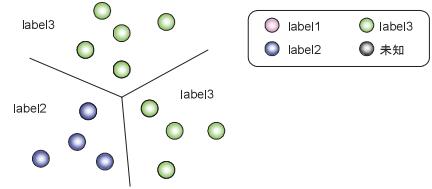


図 5. k-means 法によるラベル付けの例

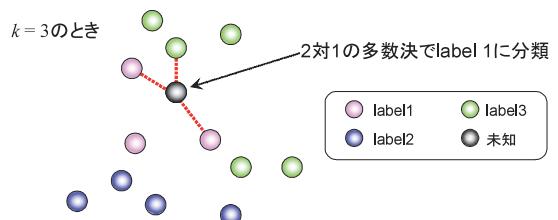


図 6. k-NN 法によるラベル付けの例

k-means 法では、図 5 のように、各クラスタ内のニューロンのラベルの多数決でクラスタのラベルを決定する。このため、クラスタごとの大局的なラベル付けが行われるため、SOM のマップ上の位相情報の一部が喪失する可能性があった。

この欠点を改善するために、次のような k-NN 法 (k-nearest neighbor; k 最近接傍法) を採用する。この方法は、図 6 のように、着目する点から距離が近い順に k 個の点を算出し、それら k 個の中の多数決でパターンを識別する方法である。

本研究ではクラスタ数 K を 1~20 までに設定して試行し、最適な K によるクラスタを採用した。また、クラスタの評価指標には Davies-Bouldin index(DBI)[9]を用いた。DBI はクラスタがコンパクトかつ十分に分離されているかという指標である。本研究では DBI 値が最小となるクラスタを最適クラスタとして採用した。

致死性不整脈の検出を行うために、ECG 波形と RVV 波形パターンの分類および検出を以下の手順で行った。

- 1) ECG と RVV から特徴ベクトルを算出
- 2) 入力データを各ニューロンにラベル付けされた SOM に提示し、最整合となるニューロンを算出
- 3) 再整合ニューロンのラベルを、その入力の波形パターンとして分類
- 4) VF/VT と分類されたデータを検出

2.1.4 学習させたデータの種類と入力ベクトルの選択

SOM を学習させる入力ベクトルとして 2 四のイヌから得られたデータを用いた。このデータを視察により分類し、次の 4 種類のように選択した。

- **VF** : 250 拍 (5 イベント)
- **VT** : 280 拍 (6 イベント)
- **Shock** : 125 拍 (VF 誘発通電刺激 ; 32 イベント)
- **Other** : 335 拍 (正常状態、および Shock・VF・VT 以外)

容積信号 RVV の有効性を確認するために、入力ベクトルを上述の 15 次元にしたものと、これらから 9)~15)までの RVV 情報を除いた 9 次元のものの 2 種類の入力ベクトルにして SOM を学習させた。

2.1.5 RR 間隔のみを用いた判別法との比較

提案したアルゴリズムは、ECG 信号ばかりでなく心室容積信号を入力情報として利用することを前提としている。心室容積信号を加えたことが真に妥当であるかどうかを確かめるために、SOM への入力信号として、2.1.2 の ECG 信号と心室容積信号の両方の情報を含む 1)~15)までの 15 個の要素をすべて使った場合と、ECG 信号のみに関係する 1)~8)の 8 個の要素を用いた場合とを比較した。

2.2 パターンマッチングのタイミングの改善

パターンマッチングは RR 間隔ごとに行うのが簡単である。しかしこのようにすると、アーティファクトによる孤立した結果もそのとおりに判定してしまう。そこで図 7 のように、第 t 拍の判定結果が前の拍（第 $t-1$ 拍）と異なっている場合、判断を一時保留し、次の第 $t+1$ 拍の判定が第 $t-1$ 拍と同じ場合には、第 t 拍は第 $t-1$ 拍と同じ判定として出力する。

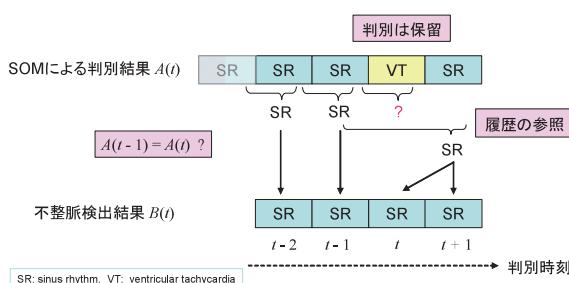


図 7. パターンマッチングのタイミング

2.3 計算量の低減と個体差・時変性・電極配置の影響の排除

本アルゴリズムをシングルチップ・マイコンに実装する場合、計算量の低減が必要である。SOM によるマッチングの計算量は、特徴ベクトル次元とニューロン数の積に比例する。特徴ベクトルとニューロン数の最適化が必要であるが、最適化のための明確な基準はない。現段階では試行錯誤により入力ベクトルの選択を行わざるを得ない。

一方、2.1.2 で提案した入力ベクトルは、変量が波形の絶対値に強く依存する。すなわち、ECG は電極の位置で波形が異なったり、R 波の極性は時間により反転する (VF 発症時等)。また容積信号の場合、VF/VT 発症時の容積の変化は個体により異なるし、心臓が弱ってくると正常時でも心室が肥大する。

そこでここでは、入力数を低減するとともに、個体差・時変性・電極配置の影響をできるだけ排除するため、ECG 信号については絶対値に依存する波形情報ではなく間隔情報のみを使うことにし、RVV についてはキャリブレーションを正確に取ることを前提として、入力ベクトルを次のように変更した。

- 1) 現在拍の RR 間隔
- 2) 1 拍前の RR 間隔
- 3) 2 拍前の RR 間隔
- 4) RVV の最小値
- 5) 一回拍出量 (RVV の最大値と最小値の差)

また、マップサイズ (ニューロン数) は 48 個 (12×4) とした。さらに図 8 のように、領域判定を行う際、境界に隣接しないニューロンは判定に寄与しない。そこで実際の判定には、図 9 のように、隣接するニューロンのみを使う。図 9 の場合は計算対象のニューロン数が 48 個から 18 個に低減することになる。

RVV 計測には、コンダクタンス・カテーテルの原理を使用するので高周波電流を通電する必要がある。これは電力消費が大きいため、体内埋め込みを考慮する場合、RVV の連続的計測を行うことは現実的ではない。

そこで、マイコンにおけるソフトウェアでは RR 間隔をモニタし、これが短くなったら RVV の計測を初めて開始する方式を取った。

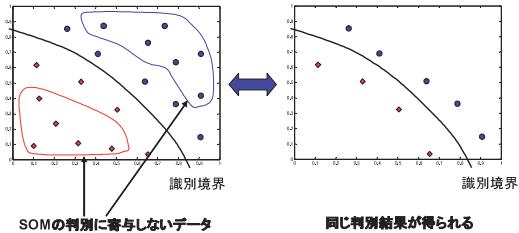


図 8. 判定に寄与するニューロン

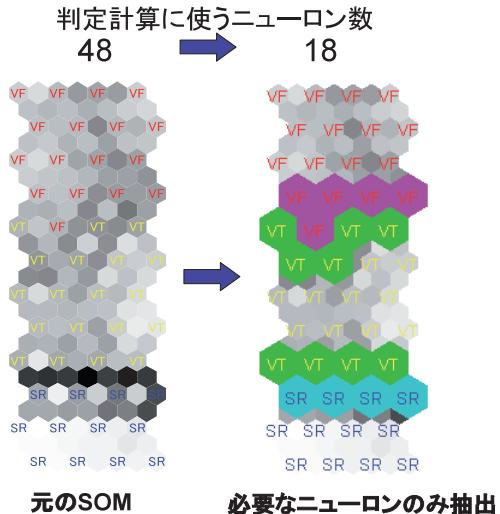


図 9. 判定に必要なニューロンの例

2.4 シングルチップ・マイコンへの実装と動物実験

本研究では、マイコン SH-2（日立製作所製 SH7045F）を搭載したマイコンボード（アルファプロジェクト製）上に SOM の判定アルゴリズムを実装した。このボードを使って図 10 のような実験系を構成した。このときのソフトウェアのフローチャートを図 11 に示す。

実験では 3 頭のイヌを用いた。人工呼吸の麻酔下で心内 ECG 信号と RVV 信号を計測し、これを生体アンプを通してマイコンボードの AD コンバータに導いた。検出結果は 2 ビットのデジタル信号として外部の PC のデジタル・インプットへ導いた。

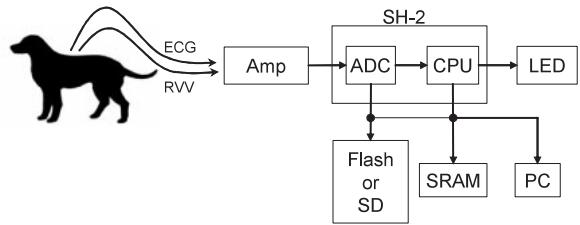


図 10. 動物実験

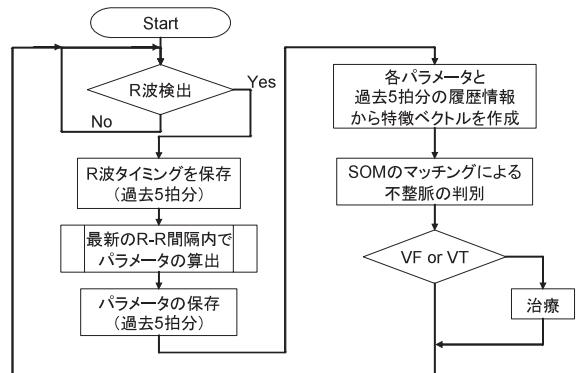


図 11. ソフトウェアのフローチャート

3. 結果 [10-12]

3.1 SOM による学習とクラスタリングの結果

3.1.1 学習後の SOM の状態

2.1 で述べた方法に従って、SOM の学習を行った。学習を行った SOM は、ECG と RVV の特徴パラメータの学習による SOM と、ECG のみの特徴パラメータの学習による SOM の計 2 種類である。

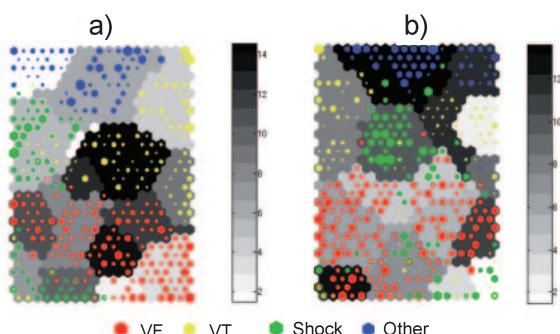


図 12. クラスタ上の学習データの分布。a) ECG および RVV の学習, b) ECG のみの学習

学習後に得られた SOM を k-means 法を用いてクラスタリングした。クラスタ数を 20 までに設定して実行し、DBI 値が最小となるクラスタ数 K を最適クラスタとして採用した。ECG と RVV 学習の SOM においては $K=15$ となり、ECG のみの学習による SOM では $K=14$ となった。k-means 法により分割したクラスタにおける学習データの分布を図 12 に示す。ここで、各六角形は最適合として反応したニューロンを表し、その大きさはそのニューロンを最適合とした学習データ数に比例している。各クラスタ内に最も多く分布した学習データのラベルを採用し、これを SOM 上に改めて記したもののが図 13 である。

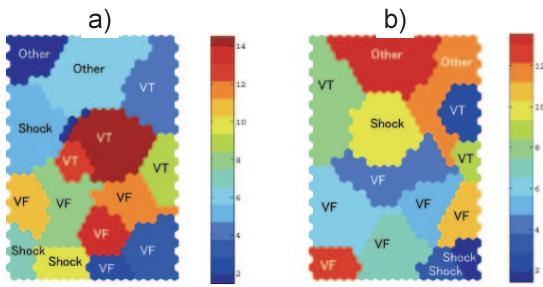


図 13. k-mean 法によるクラスタリング結果. a) ECG および RVV の学習, b) ECG のみの学習

図 13において ECG と RVV の学習を行った SOM では各クラスタにほぼ 1 種類の学習データが分布しているのに対し、ECG のみを学習した SOM では ECG と RVV の学習を行った SOM に比べ各クラスタに複数の学習データが分布していることがわかる。

3.1.2 既学習データの VF/VT 検出結果

各ニューロンにラベル付けした SOM を用いて既学習データを分類し、VF/VT の検出を行った。VF は 5 エピソードから VF 波形を 645 拍含む全 980 拍のデータを対象とした。また、VT は 6 エピソードから VT 波形を 288 拍含む全 649 拍のデータを対象とした。ここで検出率の評価指標として、感度と特異度を用いた。この結果を図 14 に示す。ただし、パターンマッチングは RR 間隔ごとに行った。

VF の感度および VT の特異度は ECG と RVV を学習データとした場合と ECG のみを学習データとした場合ともに 95% を超える高い値となった。

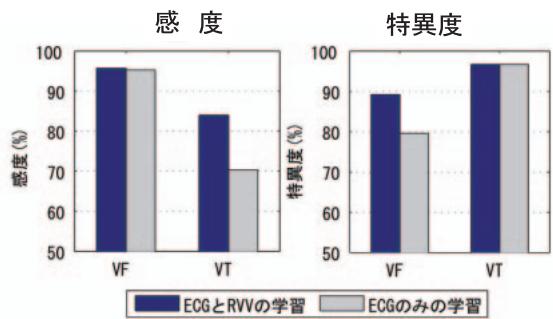


図 14. 既学習データの VF/VT 検出結果に関する ECG と RVV の両方を入力とした場合と ECG のみを入力とした場合の比較

3.1.3 未学習データの VF/VT 検出結果

前節と同様に未学習データにおいても VF/VT の検出を行った。VF は 13 エピソードから VF 波形を 1845 拍含む全 2988 拍のデータを対象とした。また、VT は 13 エピソードから VT 波形を 576 拍含む全 1277 拍のデータを対象とした。この結果を図 15 に示す。

VT の特異度を除き、ECG と RVV の両方を入力とした場合の方が ECG のみを入力とした場合より優れている。

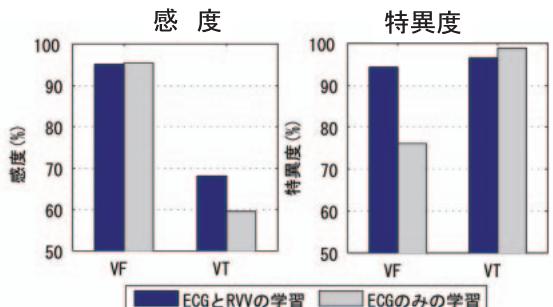


図 15. 未学習データの VF/VT 検出結果に関する ECG と RVV の両方を入力とした場合と ECG のみを入力とした場合の比較

3.2 k-NN 法による判別法の改良

図 16 は、同一データに対して学習させた SOM に基づいて k-means 法と k-NN 法を使った場合の感度と特異度を示したものである。図から明らかな

ように、SR（正常洞調律）、VF、VTのいずれの場合も、k-means法よりもk-NN法の感度および特異度の向上が見られた。

そこでこれ以降の判定法ではk-NN法を使うことにした。

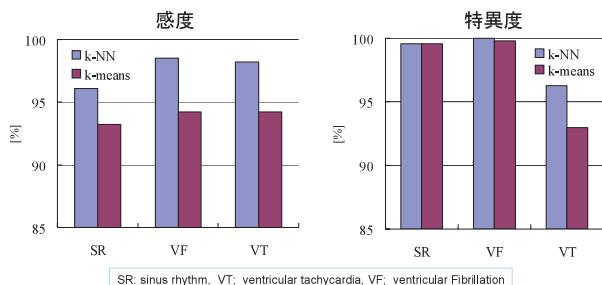


図 16. 同一データに対して学習させた SOM に基づいて k-means 法と k-NN 法を使った場合の感度と特異度

3.3 k-NN 法および改善したパターンマッチング法を用いたときの RR 間隔の閾値による方法、ECG を入力とする SOM、および ECG と RVV を入力とする SOM の比較

図 17 は、SR, VT, および VF それぞれについて 80 拍ずつ抽出し、それぞれ、13 エピソード、6 エピソードおよび 7 エピソードを入力データとして、RR 間隔の閾値による方法、ECG を入力とする SOM、および ECG と RVV を入力とする SOM を比較したものである。ここで、RR 間隔の閾値は、VT-VF の判別に対しては 0.16 s であり、SR-VT の判別に対しては 0.32 s とした。また、SOM の判定では k-NN 法および 2.2 で説明した改善したパターンマッチング法を用いた。この場合の入力ベクトルは、マイコンでの適用性を考慮し、次の通りに縮小した。

- 1)RR 間隔
- 2)RR 間隔の 5 拍分の分散
- 3)RS 間隔
- 4)S 波値
- 5)RVV の最小値
- 6)一回拍出量

同図のように、 $p < 0.05$ で有意差があったのは、VT および VF の感度と、VT の特異度であり、いずれの場合も ECG と RVV の両方を入力とする SOM が優れていた。

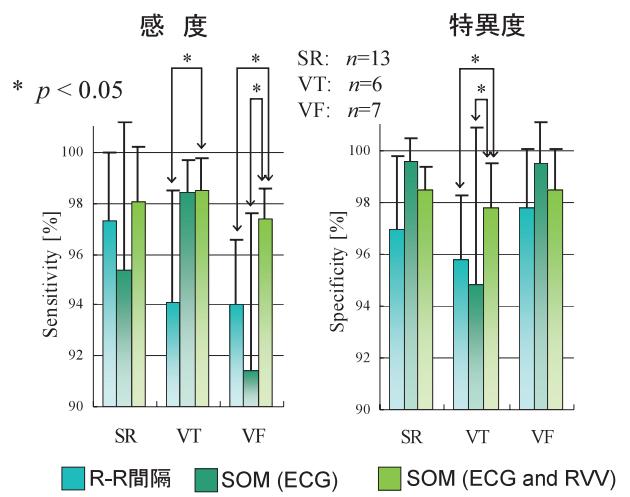


図 17. k-NN 法および改善したパターンマッチング法を用いたときの RR 間隔の閾値による方法、ECG を入力とする SOM、および ECG と RVV を入力とする SOM の比較

3.4 シングルチップ・マイコンによる判定装置を用いた動物実験

2.3 の改良アルゴリズムを 2.4 で述べたようなシングルチップ・マイコン搭載ボードで実現した。この装置を使い、3 匹のイヌ (A, B, C) で動物実験を行った。

イヌ A では、過去の実験で得られた別のイヌのデータに基づいて学習した SOM を使って判定することを試みた。このときの VT に対する判定例を図 18 に示す。この場合、SR (正常洞調律) から VT に変わっても R 波のミストリガにより 2 秒程度の間 SR と誤診している。また、VT と判定し始めてからも一回拍出量が小さい場合の一部で VF と誤診している。

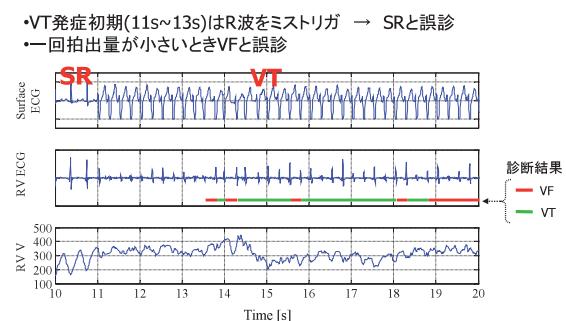


図 18. SR→VT 時の判定例 (イヌ A. 学習データはイヌ A と異なる過去の実験でのイヌのデータ)

イヌ B では、同一のイヌのデータを用いてその場で SOM の学習を行い、これに基づいて判定を行った。学習に必要な時間はパソコン (Pentium4 ; 1 GHz) で約 5 分であった。このときの例を図 19 に示す。RVV に強い呼吸性変動があるが、VT と VF を正しく判定している。

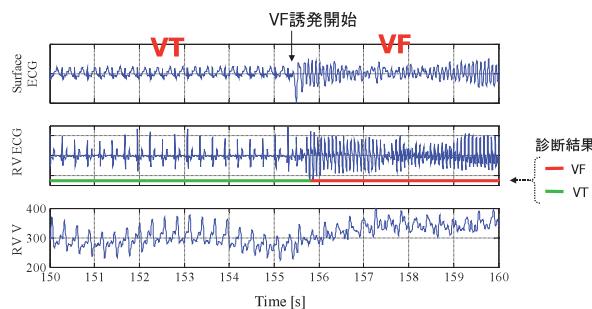


図 19. VT→VF 時の判定例（イヌ B. 学習データはイヌ B と同一）

イヌ C では、電力消費を低減するため、図 20 のように、連続的な容積計測は行わず RR 間隔が 0.4s より短くなったときに限り容積計測を開始し、0.4s 以上の RR 間隔が 5 拍持続すれば計測停止するというアルゴリズムを使って判定を行った。ただし実際には、記録を残すため容積信号自体は計測し、判定アルゴリズムにおいてのみ 0.4s 以上の RR 間隔の SR 時には容積信号を用いないということを行った。学習を使ったデータはイヌ B のものである。

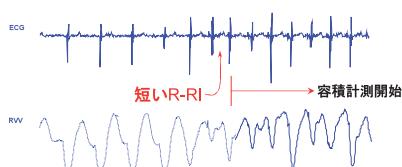


図 20. 電力消費を低減するため連続的な容積計測を行わない例（イヌ C）

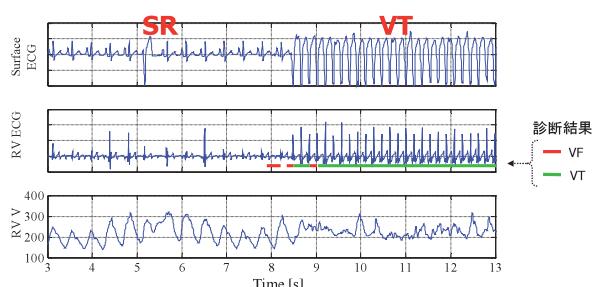


図 21. SR→VT 時の判定例（イヌ C. 学習データはイヌ B のもの）

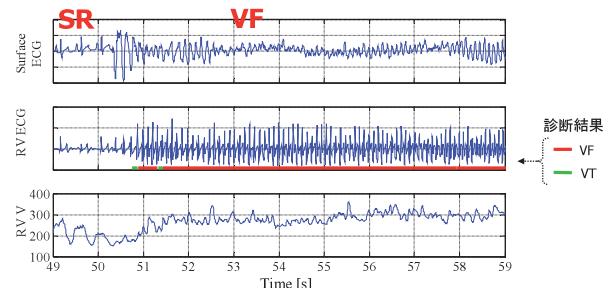


図 22. SR→VF 時の判定例（イヌ C. 学習データはイヌ B のもの）

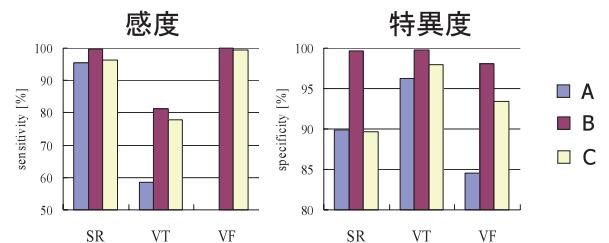


図 23. 3 匹のイヌ (A, B, C) の感度および特異度。B は学習したデータで判定し、A と C は学習したデータとは異なるデータで判定したもの。イヌ A では VF 誘発は行わなかった。

このときの結果を図 21 (SR→VT 時) と図 22 (SR→VF 時) に示す。これらの図から、容積計測を常時行わなくとも正しい判定が行えることがわかる。

3 匹のイヌ (A, B, C) の感度および特異度をまとめると図 23 のようになる。ただし、イヌ A においては VF を誘発しなかったので感度は算出していない。3 匹とともに VT の感度が低い。特に VT の感度は 60% 未満である。これは他の個体で得られた SOM よりも、自己のデータで作った SOM のほうが有効であることを示している。ただし、イヌ C の値はイヌ B のデータで学習したものであるので、RVV のキャリブレーションなどをより正確に行えば他の個体から得られる SOM も有効であると考えられる。

4. 考察

4.1 SOM の基本的有効性

図 14 と図 15 から、VF は高い確率で検出可能であり、VT でないものを VT として誤検出する確率が低いことがわかる。一方、VF の特異度および

VT の感度は両手法においてやや低い値に留まった。全体として、ECG と RVV の学習手法のほうが ECG のみの学習手法より精度が高い。これは容積計測が有効であることを示している。

図 16 から、SOM に基づく判定法は k-mean 法よりも k-NN 法の方が優れていることがわかった。ただし、k-NN 法は k-mean 法よりも計算量が多いという欠点がある。しかし、この欠点はシングルチップ・マイコンに実装化できないほどではない。

図 17 は、入力を 15 種類からシングルチップ・マイコンでも動作可能な 6 種類 (ECG と RVV の両方の情報を含む) に低減しても、感度と特異度とともに 97% 以上であり、実用上十分なレベルであることを示している。

4.2 シングルチップ・マイコンによる判定装置の有効性

図 18 は、容積信号がその性質が時変的であり、かつ個体差のあるものであるということを意味するものである。したがって、判定アルゴリズムに容積信号を使う場合は、埋め込み手術中に正確なキャリブレーションが必要である。さらに、埋め込み手術中に得られるデータをその場で使って SOM の学習を行うことが必要である。ただし、シングルチップ・マイコンによる判定装置用の SOM の学習に必要な時間は、パソコンで約 5 分であったので、手術中でも十分実行できる可能性がある。

図 18 の R 波のミストリガは、判定閾値を時間的に変動させることで対処可能であるので本質的な問題ではない。ただし、VT なのに VF と誤判断しているのは、主として一回拍出量 (RVV の拍内最大値と最小値の差) であることがわかっている。VT の主たる特徴はある程度規則的な周期性があるので RVV 波形のこの要素を入力とすると改善する可能性がある。

図 19, 21, 22 のように、2.1.2 の 1)~15)までの 15 個の要素を入力ベクトルとした場合でなくとも、6 次元のベクトルでも十分な VT と VF の検出ができることがわかった。さらに、電力消費を軽減する方法として、RR 間隔が短くなったときのみ心室容積信号を計測する方法でも判定精度に影響がほとんどないこともわかった。

図 23 は、イヌ A や C のように学習を使ったデータと異なるデータに対して判定をするときには、判定精度が高くないことを意味している。ただし、イヌ B のように、両者が一致している場合には、

SR・VF の感度および SR・VF・VF の特異度が高い。したがって、埋め込み手術中の学習を行い、かつ VT の感度を上げる工夫をすることにより、本提案法は十分に実用的になると判断することができる。

5. おわりに

本研究では、致死性不整脈検出のためのアルゴリズムとして提案した SOM 法の実用化を目指し、その判別能力の向上を目的とする改良、計算量の低減化、シングルチップ・マイコンへの実装化、および実装したシステムのイヌを用いた動物実験による有効性の評価を行った。

その結果、既学習データについては VF/VT の自動分類が、感度で 80%/98% 程度、特異度で 98%/95% 程度で可能であることを明らかにした。このことは、心室容積の正確なキャリブレーションと埋め込み手術中に SOM の学習を行うことを前提とすれば、本方法が十分実用的であることを意味している。さらに、電力消費を軽減するために RR 間隔が短くなったときのみ心室容積信号を計測する方法を使っても、判定精度にはほとんど影響がないことも明らかになった。

今後は、実際の超 ICD で想定されている簡易的な計測で得られる心室容積情報だけでも本アルゴリズムが機能するかどうかを確かめる必要がある。また、本方法の特徴である心室容積情報の処理により、例えば、検出に 2 電極が必要であった上室性不整脈などが検出可能であるかどうかなどを検討すべきであると思われる。

文献

- [1] ML リソース : 除細動器 defibrillator [Online]. <http://www.medmk.com/mm/add/defibrillator.htm> [2007].
- [2] Eberhardt F, Peters W, Bode F, and Wiegand UK. R wave undersensing caused by an algorithm intended to enhance sensing specificity in an implantable cardioverter defibrillator. *PACE* **26**, 1776-1777, 2003.
- [3] Kouakam C, et al. Performance of a dual-chamber implantable defibrillator algorithm for discrimination of ventricular from supraventricular tachycardia. *Europace* **6**, 32-42, 2004.
- [4] Przybylski A, et al. Verification of implantable cardioverter defibrillator (ICD) interventions by

- nonlinear analysis of heart rate variability -- preliminary results. *Europace* **6**, 617-624, 2004.
- [5] Sinha AM, et al. Clinical experience with a new detection algorithm for differentiation of supraventricular from ventricular tachycardia in a dual-chamber defibrillator. *J Cardiovasc Electrophysiol* **15**, 646-652, 2004.
- [6] Aliot E, Nitzsche R, and Ripart A. Arrhythmia detection by dual-chamber implantable cardioverter defibrillators. A review of current algorithms. *Europace* **6**, 273-286, 2004.
- [7] Kohonen T. Self-organized formation of topologically correct feature maps. *Biological Cybernetics* **43**, 59-69, 1982.
- [8] Roy A. A survey on data clustering using self-organizing maps. <http://www.cs.ndsu.nodak.edu/~amroy/courses.html>.
- [9] Davies DL and Bouldin DW. A cluster separation measure. *IEEE Transactions on Pattern Analysis and Machine Intelligence* **PAMI-1**, 224-227, 1979.
- [10] Yoshizawa M, Inagaki M, Uemura K, Sugimachi M, and Sunagawa K. Development of detection algorithm of fatal arrhythmia for a new implantable cardioverter defibrillator. In *Proceedings of 27th IEEE-EMBS, Shanghai, China*, CD-ROM, 2005.
- [11] 吉澤誠, 稲垣正司, 上村和紀, 杉町勝, 砂川賢二. 左心室容積信号を用いたICD用致死性不整脈検出アルゴリズムの開発. 第25回生体医工学会大会, 2005.
- [12] Kinoshita H, Yoshizawa M, Inagaki M, Uemura K, Sugimachi M, and Sunagawa K. Development of an algorithm for early detection of fatal cardiac arrhythmia for implantable cardioverter-defibrillator using a self-organizing map. In *Proceedings of International Symposium on Bio- and Nano-Electronics*, 101-102, 2006.