

ニューラルガスを用いた階層型 k 近隣法による 冠動脈組織性状の判別速度および精度の向上

Improvement of Speed and Accuracy for Intravascular Ultrasound-based Tissue Classification by Hierarchical k-Nearest Neighbor Using Neural Gas

徳永 憲洋¹, 田中 宏樹², Gancho VACHKOV², 末竹 規哲², 内野 英治^{1,2}

1) 一般財団法人ファジィシステム研究所

2) 山口大学理工学研究科

Kazuhiro TOKUNAGA¹, Hiroki TANAKA², Gancho VACHKOV²,
Noriaki SUETAKE², Eiji UCHINO^{1,2}

1) *Fuzzy Logic Systems Institute*

2) *Graduate School of Science and Engineering, Yamaguchi University*

Abstract: In this paper, we propose a method to advance the speed and accuracy for tissue classification of Intravascular Ultrasound (IVUS) data using Hierarchical k-Nearest Neighbor (HkNN). In this method, the neural gas is used to decide several representative vectors from the training vectors in the HkNN. The speed of calculation for tissue classification by HkNN is thus advanced. Moreover, the reliability and accuracy of the classification results are improved. They are examined by the experiments using the true IVUS data.

Keywords: IVUS (Intravascular Ultrasound), Tissue Classification, Hierarchical k-Nearest Neighbor, Neural Gas

Eiji UCHINO

Yoshida 1677-1, Yamaguchi, Yamaguchi, 753-8512, Japan

Tel: 083-933-5699, E-mail: uchino@yamaguchi-u.ac.jp

1. はじめに

心筋梗塞は冠動脈の内面にできたプラークと呼ばれる異常な組織の破綻で引き起こされる。心筋梗塞の早期予防のためには、血管内組織性状を事前に調べ、破綻し易い不安定プラークか、そうでない安定プラークかを判断する必要がある。このためには、プラークを構成する物質の組織性状（脂質・線維・石灰他）とその構造を詳細に把握しなければならない。主に組織性状の把握は、カテーテルを用いた血管内超音波（Intravascular Ultrasound: IVUS）法[1]によって得られる Radio Frequency (RF) 信号の解析により行われる。

これまでの研究においてわれわれは、組織性状判別法として k 近隣法の拡張である階層型 k 近隣法（Hierarchical k-Nearest Neighbor: HkNN）法を提案し、その有効性を示した[2]。しかしこれまでの HkNN 法による組織性状判別は、クラス判別の計算速度、訓練ベクトルの選別の二点において改良の余地があった。

即ち、k 近隣法は入力ベクトルと全訓練ベクトルとの距離を計算するため、クラス判別に時間がかかる。現場ではカテーテル挿入と同時にプラークの診断が要求されるため、組織判別の速度は重要である。一方、判別速度を上げるために訓練ベクトルを予め間引くことも考えられるが、膨大な数のデータから訓練ベクトルとして利用できるデータをいかに取捨選択するかが問題となる。

本研究では HkNN による組織性状判別を高速かつ高精度に行うため、ニューラルガスを用いた訓練ベクトルの選別法を提案する。即ち、多くの訓練ベクトルの中から代表的なベクトルをニューラルガスの学習で決定する。これによりニューラルガスの参照ベクトルが HkNN の訓練ベクトルとして利用される。本提案手法は HkNN の判別速度を上げるだけでなく、判別精度の向上にも寄与する。

本稿では提案手法の概略を説明すると共に、実験により本提案手法の有効性を示す。

2. IVUS法を用いた階層型k近隣法による組織性状判別

2.1 IVUS法

先端にプローブと呼ばれる超音波探触子を取り付けられたカテーテルを血管内に挿入し、プローブを回転させながら超音波を送受信する。このとき観測される信号をRadio Frequency (RF) 信号と呼ぶ。RF信号の信号強度は血管組織の場所および性状によって異なる。RF信号はプローブを回転させながら血管内全方向について観測される。

2.2 階層型k近隣法

階層型k近隣 (Hierarchical k-Nearest Neighbor: HkNN) 法は従来のk近隣法の拡張であり、特徴空間だけでなく観測空間においても、隣接した点で観測した特徴ベクトル群は同じクラスに属する可能性が高いという仮定に基づきクラス分類を行う。

アルゴリズムの大まかな流れは、まず特徴空間におけるk近隣法を行い、その後、観測空間におけるk近隣法を行う。

特徴空間におけるk近隣法

今、特徴ベクトル w_i ($i=1, \dots, N$) が得られているとする。これらの特徴ベクトルのクラスは既知であり、各ベクトルのクラスを ω_i とする。また、この特徴ベクトル w_i を本稿では訓練ベクトルと呼ぶ。

クラスが未知の特徴ベクトル x が入力されたとき、そのクラスは次式によって求められる。

$$l = \arg \max_{\omega} \sum_{i=1}^N \delta(w_i, \omega_i, \omega) \quad (1)$$

$$\delta(w_i, \omega_i, \omega) = \begin{cases} 1 & (\text{if } \|w_i - x\| \leq r(k), \omega_i = \omega) \\ 0 & (\text{otherwise}) \end{cases}$$

ここで $r(k)$ は入力された x から k 番目に近い訓練ベクトルとのユークリッド距離を表す。式(1)では、まずクラスが未知の特徴ベクトルに対して、特徴空間上のk近傍内に位置する訓練ベクトルを算出する。その後、それらのクラスの多数決を取り、入力された特徴ベクトルのクラスを決定する。

観測空間におけるk近隣法

特徴空間におけるk近隣法で入力ベクトルの集合 $\{x_n\}$ に対してクラス割り当てをした後に、そのクラス情報を基に観測空間上にて同様にk

近隣法を行う。観測空間上での入力ベクトル間の距離を計算する以外は、ほぼ式(1)と同様である。

2.3 階層型k近隣法による組織性状判別

IVUS法を用いた階層型k近隣法による組織性状判別では、RF信号に短時間離散フーリエ変換を施して得られるパワースペクトル集合を、特徴ベクトル集合として用いる。本実験では、予め医者による所見が得られているプラーク組織のパワースペクトルを訓練ベクトルとして用いる。

プラーク組織として、主に脂質性組織と線維性組織の判別を行う。具体的には、医者による所見が得られている二つの組織、およびそれ以外のプラーク内組織の三組織に対するRF信号からパワースペクトルを抽出し、これらを訓練ベクトルとする。このときHkNNでは所見の得られているデータの分だけ訓練ベクトルが増えるため計算量が増大する。そのため、代表的な訓練ベクトルだけを選別する方法が必要となる。

3. ニューラルガスを用いた訓練ベクトルの自動選別

3.1 ニューラルガスのアルゴリズム

ニューラルガスはベクトル量子化法の一つであり[3]、他のベクトル量子化法に比べ量子化誤差が少ないことが報告されている。本稿では結果に一貫性を持たせるため、バッチ型のニューラルガスを用いる。以下にバッチ型ニューラルガスのアルゴリズムを示す。

ニューラルガスのアルゴリズムは、以下の評価プロセス、競合プロセス、適応プロセスを繰り返すことにより学習が進む。

初期化

今、 d 次元のデータベクトル x_i が N 個あるとする。またニューラルガスは K 個の参照ベクトル w_k から構成されているとする。学習の初期段階では w_k は乱数により初期化される。

評価プロセス

全データベクトルと全参照ベクトルの距離を以下の式で計算する。

$$d_{i,k} = \|x_i - w_k\| \quad \forall i, \forall k \quad (2)$$

ここで $d_{i,k}$ は i 番目のデータベクトルと k 番目の参照ベクトルとの距離を表す。

競合プロセス

評価プロセスで求めた距離から、各データベクトルに対する参照ベクトルの順位を求め、各参照ベクトルの学習量を決定する。ここで $r_{i,k}$ を i 番目のデータベクトルに対する k 番目の参照ベクトルの順位とすると、学習量 $\psi_{i,k}$ は次式で表わされる。

$$\psi_{i,k} = \frac{\phi_{i,k}}{\sum_i \phi_{i,k}} \quad (3)$$

$$\phi_{i,k} = \exp\left(-\frac{r_{i,k}}{\lambda(t)}\right) \quad (4)$$

ここで $\lambda(t)$ は学習ステップ t に関する単調減少関数で、本研究では $\lambda(t)$ を以下で定義する。

$$\lambda(t) = (\lambda_{\max} - \lambda_{\min}) \exp\left(-\frac{t}{\tau}\right) + \lambda_{\min} \quad (5)$$

τ は時定数である。

適応プロセス

全参照ベクトルを以下の式で修正する。

$$\mathbf{w}_k \leftarrow \sum_{i=1}^N \psi_{i,k} \mathbf{x}_i \quad (6)$$

3.2 ニューラルガスを用いた訓練ベクトルの選別および階層型 k 近隣法による組織性状判別

HkNN のクラス判別では全訓練ベクトルと入力ベクトルとの距離を計算する必要がある。そのため、訓練ベクトルの数が増えれば計算量も増大する。

これまでの IVUS 法を用いた HkNN による組織性状判別では、全訓練ベクトルを使用するか、代表的な訓練ベクトルを手動あるいは決められた規則に従って選別していた。しかし、この方法では手間がかかるだけでなく、結果が代表ベクトルの選別に依存する。また組織毎の訓練ベクトルは特徴空間内で密集して分布しているため、単に訓練ベクトルの数を調節しただけでは識別精度は上がらない。

ニューラルガスを用いた訓練ベクトルの選別では、まず組織毎の訓練ベクトルの代表ベクトルをニューラルガスで求める。この代表ベクトルを HkNN の訓練ベクトルとする。

入力ベクトルに対する組織性状判別では、多数決の際に入力ベクトルと訓練ベクトルの距離を重み付けし判別に利用する。即ち、式(1)は次のようになる。

$$l = \arg \max_{\omega} \sum_{i=1}^N \delta(\mathbf{w}_i, \omega_i, \omega)$$

$$\delta(\mathbf{w}_i, \omega_i, \omega) = \begin{cases} \exp(-\|\mathbf{w}_i - \mathbf{x}\|/\varepsilon) \\ \quad (\text{if } \|\mathbf{w}_i - \mathbf{x}\| \leq r(k), \omega_i = \omega) \\ 0 \quad (\text{otherwise}) \end{cases} \quad (7)$$

ε は減衰パラメータであり、データの分布に合わせて調整する。これにより単純に多数決を取るよりも組織性状判別の精度が高まる。

4. 実験

4.1 実験の枠組み

本実験では、本手法の有効性を確かめるため、ニューラルガスを用いた場合と用いない場合について判別速度と判別精度の両面で比較を行う。訓練ベクトルの選別は脂質性組織、線維性組織、およびそれ以外のプラーク内組織の三組織で行う。

ニューラルガスを用いない場合は訓練ベクトルをランダムに選別する。また判別精度は真陽性率 (True Positive Rate: TPR) と真陰性率 (True Negative Rate: TNR) で評価する。

比較実験では選別した訓練ベクトルの数 (ニューラルガスの参照ベクトルの数) を変えた場合の判別速度と判別精度を評価する。また短時間フーリエ変換の窓幅は 64 点とした。本比較実験は 10 回試行した。

4.2 実験結果

実験結果を図 1～4 に示す。図 1 と 2 が脂質性組織、図 3 と 4 が線維性組織の TPR, TNR の結果である。実線がニューラルガスを用いた場合、点線がニューラルガスを用いない場合を示す。

脂質性および線維性の両組織において、ニューラルガスを用いない場合は分散が大きく結果にばらつきがあるが、ニューラルガスを用いた場合は分散が小さく結果に安定性があった。

脂質性組織において、ニューラルガスを用いた場合の TPR については高い値を示した。この結果からニューラルガスを用いることで判別精度が向上することが示唆される。

また TPR は訓練データが少ない所で高くなっている。この理由は識別境界面の複雑さのため、訓練ベクトルの数が汎化性に影響を与えていると考えられる。

一方、線維性組織の TPR についてはニューラルガスを用いると識別精度が低くなった。これについては他のデータによる検証も必要であり今後の課題である。

表 1 に計算時間を示す。訓練ベクトルの数が増えると指数関数的に計算時間が増大する。しかし、ニューラルガスを用いることにより、判別に必要な少数の訓練ベクトルだけを選別でき、汎化性の向上と安定性を保ったまま計算速度を改善することができる。

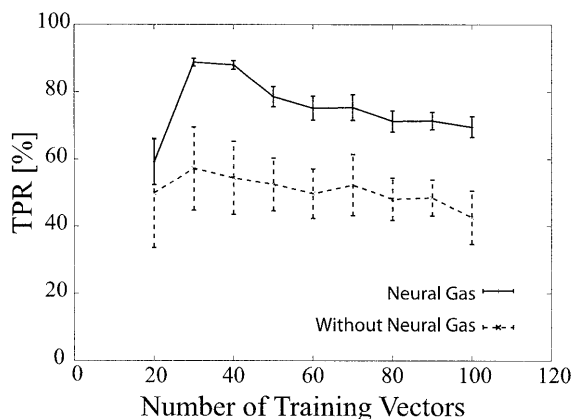


図 1. 訓練ベクトルの数と TPR (脂質性組織)




図 2. 訓練ベクトルの数と TNR (脂質性組織)




図 3. 訓練ベクトルの数と TPR (線維性組織)




図 4. 訓練ベクトルの数と TNR (線維性組織)

表 1. 訓練ベクトルの数と組織判別の計算時間

訓練ベクトルの数	30	50	400
計算時間[sec]	1.90	2.17	10.78

4. まとめ

本研究では HkNN による組織性状判別を高速かつ高精度に行うため、ニューラルガスを用いた訓練ベクトルの選別法を提案した。実験により本手法が、HkNN の高速かつ高精度の組織性状判別をアシストすることが示唆された。今後の課題は、より多くの症例で評価を行うこと、および識別精度がさらに高まる特徴ベクトルの発見を行うことである。

謝辞

本研究の遂行にあたり、山口大学医学部（現日本大学医学部）の廣高史先生の協力を頂いた。また、本研究は科学研究費補助金基盤（B）課題番号 23300086 の下に行われた。

参考文献

- [1] J. B. Hodgson, et al., Clinical percutaneous imaging of coronary anatomy using an over-the-wire ultrasound catheter system, *Int. J. Cardiac Imaging*, vol. 4, pp. 187–193, 1989.
- [2] E. Uchino, et al, An ROC performance validation of hierarchical k-Nearest neighbor classifier applied to tissue characterization using IVUS-RF signal, *Proceedings of NCSP'09*, pp.333-336, Hawaii, 2009.
- [3] T. Martinetz and K. Schulten, A “neural gas” network learns topologies, *Artificial Neural Networks* (Elsevier), pp. 397-402, 1991.