

# K近傍法によるてんかん発作時脳波識別手法の提案

北川 菜<sup>1</sup> 山崎 雄貴<sup>1</sup> 土井 千章<sup>1</sup> 重野 寛<sup>1</sup>

**概要:** てんかんとは大脳の神経細胞の過剰な活動によって引き起こされる反復的な発作を生じる脳疾患である。抗てんかん薬を用いることにより、てんかんの発作を抑制できる。てんかんの確定診断及び投薬には患者の脳波を測定し医師が確認することが有効とされる。しかし、専門医や長時間の脳波測定を行える施設の不足による医療現場の負担や、適切な投薬を受け続けることの難しさが課題である。本稿では、医師のてんかん診断の補助を行うことを目的として、機械学習手法を用いて脳波データからてんかん発作時の脳波を識別するモデルを構築する。また、家庭で使用できる簡易的な脳波計を用いた識別を可能とするために識別に必要な脳波計のチャンネル数を削減する方法とその下限を検討する。識別モデルを用いることで脳波データからてんかん発作を F1 score:0.995 で識別できることを確認した。また 15 チャンネルという簡易的な脳波計で有り得るチャンネル数でも性能を大きく損なうことなく発作の識別が可能であることを確認した。

## Proposal of Epileptic Seizure EEG Identification Method Using K-Nearest Neighbor Method

SHIORI KITAGAWA<sup>1</sup> YUKI YAMASAKI<sup>1</sup> CHIAKI DOI<sup>1</sup> HIROSHI SHIGENO<sup>1</sup>

### 1. はじめに

てんかんとは大脳の神経細胞の過剰な活動によって引き起こされる反復性の発作が生じる疾患の総称であり、一部の難治性患者を除いた多くの患者は抗てんかん薬による発作の抑制が可能である [1]。てんかんの診断、投薬には医師による脳波確認が有効である一方、専門医や施設の不足による医師の負担の増加、治療へのアクセスの困難化が問題となっている。また、擬似発作と呼ばれるてんかんと似た症状の発作もてんかんに対する適切な治療の妨げとなっている。てんかんの発作の識別を医師の目を通すことなく行えるならば、診断の簡易化が可能となり、これらの問題を解決することにつながる。

てんかん治療に対する医師不足は国内外で発生している。日本国内ではてんかん患者は約 100 万人存在し [2]、そのうち 15 歳以上の患者は約 90 万人である。一方てんかん専門医は国内に 714 人であり、392 人が小児科医、324 人が精神科医や脳神経科医ら成人科医である [3]。特に成人

科医に対しての患者数が多く、診断・治療に関して医師の負担は大きい [4]。国外では、てんかん患者は世界では推計 5000 万人いるとされ、そのうち 4000 万人が途上国に存在し、3000 万人が治療を受けることができない状況だと報告されている [5]。その要因として診断を行うために長時間脳波の計測を行える施設がないこと、計測した脳波からてんかん発作を識別する医師が不足していることが挙げられる。大部分のてんかん患者が服薬による症状の抑制が可能であることを考えると、診断が行えないために投薬ができないことは患者にとって非常に不利益である。

てんかん治療の最中においても課題がある。それは擬似発作によるものである [6]。擬似発作とはてんかん患者が抱える心因性の発作で、外見的な症状はてんかんとよく似ているが脳波の乱れは伴わないことが特徴である。擬似発作は心因性であるため、てんかん治療薬での改善は望めない。しかしてんかんと診断を受けた患者の発作は全ててんかん発作だと見做されやすいため、しばしば適切な投薬の妨げとなる。この擬似発作とてんかん発作の識別は脳波をとることが効果的だとされており、現在は 2-3 日程度の入院を伴う長時間脳波計測が確定診断のために行われている

<sup>1</sup> 慶應義塾大学大学院理工学研究所  
Graduate School of Science and Technology, Keio University

が、長時間の入院施設の利用は患者と病院の両者にとって負担が大きい。

これらの課題に共通するのは、てんかんは脳波を測定することにより診断、投薬、治療がスムーズに行える一方で、それを行える施設の不足や医師の不足・負担の大きさが障害となっていることである。

本稿では、てんかん発作時の脳波の自動識別と必要チャンネル数の削減を提案する。この提案は大きく二つの要素から成る。一つ目の要素は、スライド窓を用いた機械学習によるてんかんの脳波の自動識別を提案する。識別モデルは機械学習手法を適応して構築し、機械学習手法ごとに予測精度の評価を行う。この目的は医師の目を介さずにてんかんに識別し、医師不足による診断、投薬の遅れを防ぐことである。二つ目の要素は、てんかんの識別を行うために計測する脳波のチャンネル数の削減方法を提案し、識別に必要なチャンネル数の最低限度を探る。この目的は、ヘッドセット型の脳波計のような自宅で容易に脳波を計測できる機器を用いたてんかんの識別を可能にすることである。これが実現すると、長期間の入院を必要とする疑似発作との識別を自宅で行うことができるようになり、さらに途上国のように施設を整えることが難しい地域での治療を支援しやすくなる。

以下、本稿の構成について述べる。第2章で関連研究を紹介する。第3章では、本稿で用いたデータセットについて説明する。第4章では、提案手法として、識別モデル構築手法及びチャンネル数の削減方法について説明する。第5章では、本項の提案手法の評価結果を示す。最後に、第6章で結論を述べる。

## 2. 関連研究

### 2.1 複数の機械学習アルゴリズムを用いたてんかん発作時脳波識別

Khaled [7] はてんかん発作時を含む脳波データを複数の機械学習アルゴリズムに適用し、てんかん発作時脳波識別モデルを構築した。使用したデータセットはカルフォルニア大学アーバイン校が提供する178チャンネルの脳波計による脳波データ500件のオープンデータである。

1秒間の脳波データを入力とし、その時てんかん発作を起こしているかを識別するモデルを構築した。適用した機械学習アルゴリズムとそれぞれの評価指標を表1に示す。

表1 適用したアルゴリズムと評価指標 [7]

適用したアルゴリズム	Accuracy(%)	ROC 曲線の AUC
K 近傍法	95.23	0.882
ナイーブベイズ	95.73	0.959
ランダムフォレスト	97.08	0.996
ランダムツリー	93.86	0.900
ロジスティック回帰	81.93	0.529
ディジションテーブル	91.97	0.922

この研究では、測定した脳波をそのまま入力値としているため計算コストはかからないが、ロジスティック回帰による機械学習モデルでは AUC で 0.529 を記録しており、性能の向上が見込める。また、178 チャンネルという高性能の脳波計を使用した、一般に運用するには難しい条件下でのデータが使用されていた。

### 2.2 周波数分析を用いたてんかん発作時脳波識別

Mengni ら [8] は計測した脳波を周波数分析し、その結果を入力とする畳み込みニューラルネットワーク (CNN) を用いた識別モデルを構築した。使用されたデータセットはフライブルク大学病院 (UFK) のてんかんセンターで記録された128チャンネルの脳波計によるてんかん患者21人のデータ及びマサチューセッツ工科大学 (MIT) が提供するてんかん患者の23人のオープンデータである。

それぞれのデータに関し時間領域信号と周波数領域信号それぞれを入力とした CNN による識別モデルを構築し、性能指標を算出した。表2に評価指標を示す。

表2 各データの入力信号と性能指標 [8]

	入力信号	Accuracy(%)	Recall(%)	Specificity(%)
UFK	時間領域	91.1	83.8	85.1
	周波数領域	96.7	96.7	96.8
MIT	時間領域	59.5	62.3	47.9
	周波数領域	95.6	94.2	96.9

周波数分析をし周波数領域信号を入力とすることで、時間領域信号を入力とした場合より識別モデルの性能が向上することが確認された。しかし周波数分析及び CNN はいずれも計算コストがかかることが欠点として挙げられる。また128チャンネルの高性能の脳波計によって記録されたデータを使用しており、病院内で脳波を記録することが前提とされた研究となっている。

### 2.3 脳波プロット画像によるてんかん発作時脳波識別

Emami ら [9] は計測した脳波を10秒ごとのセグメントに分割し、プロットした画像を CNN の入力として識別モデルを構築した。使用されたデータセットは NTT 東日本関東医療センターと東京大学医学部附属病院で計測されたてんかん患者24人の脳波データである。

データは10秒間のセグメントに分割された後、 $244 \times 244$  の画像にプロットされた。その画像を入力として CNN を用いて識別モデルを構築し、Recall で 100%であった。

$244 \times 244$  の画像サイズは10秒間の脳波データを記録するには小さすぎるが、大きな画像データは書き出しに時間がかかる。また CNN は画像データを扱うことに適した手法ではあるものの計算コストがかかる欠点がある。そのため、画像サイズを大きくすることは困難である。

### 3. データセット

本稿では、カルフォルニア大学アーバイン校が提供するオープンソースのデータセットである、Epileptic seizure recognition data set [10] を使用した。このデータは5人の健康なボランティアと5人のてんかん患者から収集され、提供された。年齢及び性別の情報は失われている。

データは23秒間の脳波データ500件である。データはそれぞれ1, 2, 3, 4, 5の5つのうちのいずれかの状態値を持ち、各100件ずつ存在する。状態値1, 2, 3はてんかん患者の脳波データで、4, 5は健康なボランティアの脳波データである。状態値1はてんかん発作時の脳波、2はてんかん患者のうちてんかんを起こす脳領域から取られた脳波、3はてんかん患者のうちてんかんを起こさない脳領域から取られた脳波、4は健常者が目を閉じている時の脳波、5は健常者が目を開けている時の脳波を示している。全ての脳波信号は178チャンネルの脳波計で記録された。記録された脳波は173.61Hzでサンプリングされ、0.53-40Hzのバンドパスフィルタに通された後、1秒ごとのデータにされた。データは1行にX1~X178の各チャンネルの脳波の値とその時の状態値を持ち、全11500行で構成される。図1に各データの記載例を示す。

	X1	X2	X3	X4	X5	X6	X7	X8	X9	X10	...
Unnamed											
X1.V1	12	22	35	45	69	74	79	78	66	43	...
X2.V1	-41	-50	-53	-49	-35	-28	-15	-2	14	18	...
X3.V1	-45	-60	-73	-70	-70	-51	-29	-11	-7	-11	...
X4.V1	68	63	52	45	46	45	38	18	3	-4	...
X5.V1	-59	-48	-35	-22	4	18	21	17	18	11	...
X170	X171	X172	X173	X174	X175	X176	X177	X178	y		
-18	-32	-47	-53	-48	-40	-17	-23	-32	5		
34	22	4	-18	-31	-27	-26	-21	-30	5		
1	-21	-38	-44	-31	-17	4	35	59	5		
-22	-47	-68	-85	-92	-96	-83	-73	-66	5		
4	-5	-16	-29	-35	-21	3	35	66	5		

図1 Epileptic seizure recognition data set のデータ例

### 4. 提案手法

本章では、てんかん発作時脳波識別モデルの構築と、それをもとにしたモデル構築に必要な脳波計のチャンネル数の削減を提案する。本章では、識別モデルの構築を行う

際のデータ前処理及び識別モデルの構築について説明し、チャンネル数の削減手法について説明する。

#### 4.1 てんかん発作時脳波識別モデル

図2にてんかん発作時脳波識別モデル構築の概要を示す。

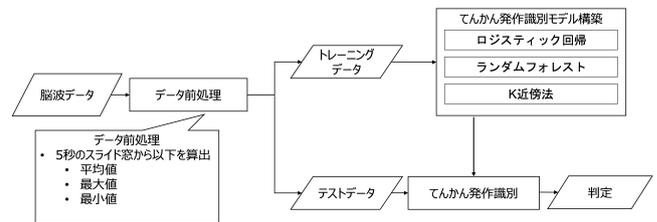


図2 てんかん発作時脳波識別モデル構築の概要

初めに取得したデータセットに対し、スライド窓を用いてデータ前処理を行った。これは脳波データが時系列データであることを生かして、時間的変化を捉えるためである。スライド窓の幅は5秒間とし、5秒間の平均値、最大値、最小値を特徴量とした。状態値はスライド窓の内5秒目のものを採用した。スライド量は1秒間とした。スライド窓は各チャンネルに適用した。機械学習手法として一般的に分類問題に用いられる手法からランダムフォレスト (RF) [11], K近傍法 (KNN) [12], ロジスティック回帰 (LR) [13] を採用し、モデルを構築した。評価方法として5分割交差検証を採用した。

#### 4.2 チャンネル数の削減手法

チャンネル数は、二つの手法を用いて削減する。1つ目の手法では、寄与度を用いる。前節で示したRFを用いて構築したモデルのチャンネルごとの寄与度を算出し、上位のチャンネルを用いたモデルを構築した。2つ目の手法ではK平均法によるクラスタリングを用いる。脳波は計測箇所が近ければ記録される波形に同じ波形成分が存在する特徴を用い [14], K平均法でチャンネルをいくつかのグループにクラスタリングし、各グループから最もチャンネル番号の若い1チャンネルを代表として用いたモデルを構築した。K平均法を用いたクラスタリングでは、各チャンネルの毎秒の脳波の値を変数とし、23変数の座標間の距離に基づいてクラスタリングを行った。

### 5. 評価

本章では、各機械学習手法で構築したてんかん発作時脳波識別モデルの予測精度を評価指標を用いて評価する。また、チャンネル数を削減して構築したモデルの予測精度を評価指標を用いて評価する。

## 5.1 評価指標

てんかん発作時脳波識別モデルの予測精度を確認するために、4つの評価指標、Accuracy (正解率), Precision (適合率), Recall (再現率), F1 score (F 値) を算出する。Accuracy, Precision, Recall, F1 score は次式 1, 2, 3, 4 で与えられる。

$$Accuracy = \frac{TP + TN}{TP + FP + TN + FN} \quad (1)$$

$$Precision = \frac{TP}{TP + FP} \quad (2)$$

$$Recall = \frac{TP}{TP + FN} \quad (3)$$

$$F1score = \frac{2 * Precision * Recall}{Precision + Recall} \quad (4)$$

ここで、TP は真陽性、FP は偽陽性、TN は真陰性、FN は偽陰性を表す。本稿ではてんかん発作時の脳波を識別するため、状態値 1 のデータを陽性、状態値 2, 3, 4, 5 のデータを陰性とする。よって陽性のデータは全体の 20% であり、陰性のデータは 80% 存在する。本稿では、総合的な性能を評価するため、Precision と Recall の調和平均である F1 score を重視して評価する。

## 5.2 評価結果

### 5.2.1 てんかん発作時脳波識別モデル

各機械学習手法におけるモデルの予測精度をデータ前処理の有無で比較した。次の図 3 に各機械学習手法における F1 score を示す。

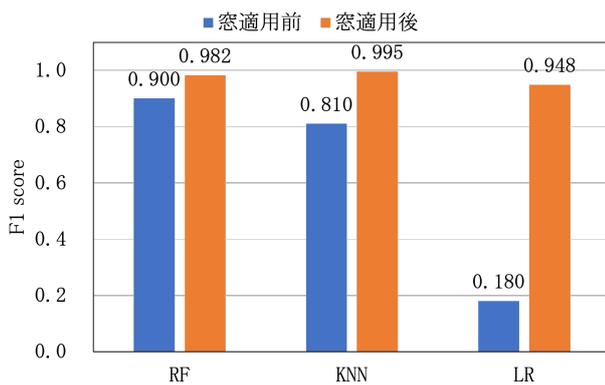


図 3 手法別モデル評価結果 (F1 score)

データ前処理を行う前のデータを適用したモデルでは RF によるモデルが最も F1 score が高く、0.948 であった。全ての機械学習手法によるモデルで、スライド窓を用いてデータ前処理を行った後のモデルの方が、行う前のモデルと比べて F1 score が改善し、KNN を用いたモデルは F1 score : 0.995 であった。

図 4 に提案手法と Emami らの手法 [9] で構築したモデル

の F1 score の比較を、図 5 に各手法における実行時間を示す。実行時間はデータ前処理後、トレーニングデータを入力しモデルを構築してから、テストデータを入力し識別結果を出力するまでの時間を指す。Emami らの手法 [9] とは、10 秒間の脳波をプロットした画像を入力として畳み込みニューラルネットワーク (CNN) を用いる手法である。

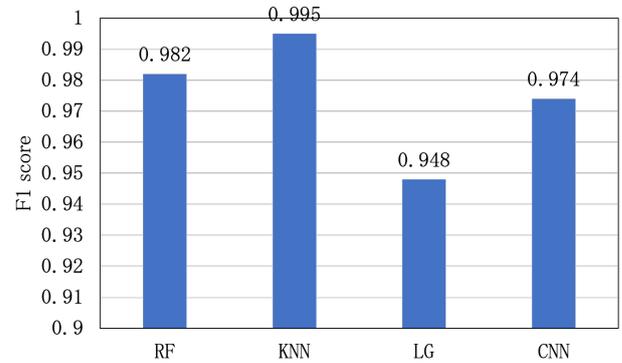


図 4 提案手法と関連研究手法の比較 (F1 score)

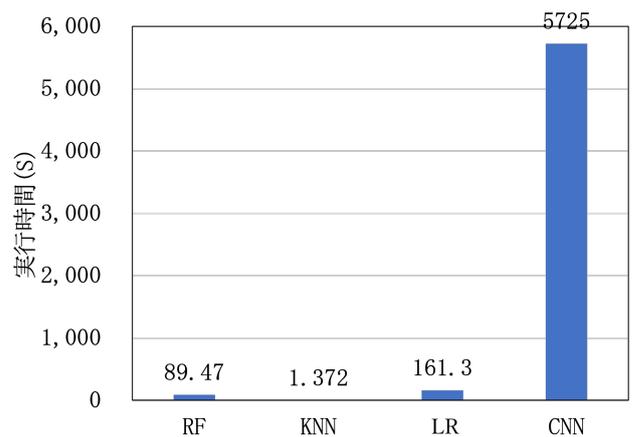


図 5 提案手法と関連研究手法の比較 (実行時間)

Emami らの手法 [9] を本稿と同じデータに適用した場合の F1 score:0.974 であり、提案手法の F1 score を下回った。提案手法は LR によって構築されたモデルが最も実行時間が長かったが、Emami らの手法 [9] の 3% 以下の時間で識別が可能であった。このことから本提案手法は関連研究と比較して、より短い時間で同等かそれ以上の識別性能を持つことを確認した。

### 5.2.2 チャンネル数の削減

本節では、Emami らの手法 [9] 以上の性能を維持することを目標にチャンネル数の削減を行う。初めに、提案した二つの削減方法のうち、どちらがモデルの性能に与える影響が小さいかを検討した。寄与度を用いた手法とクラスタリングを用いた手法で、全 178 チャンネルから 30 チャン

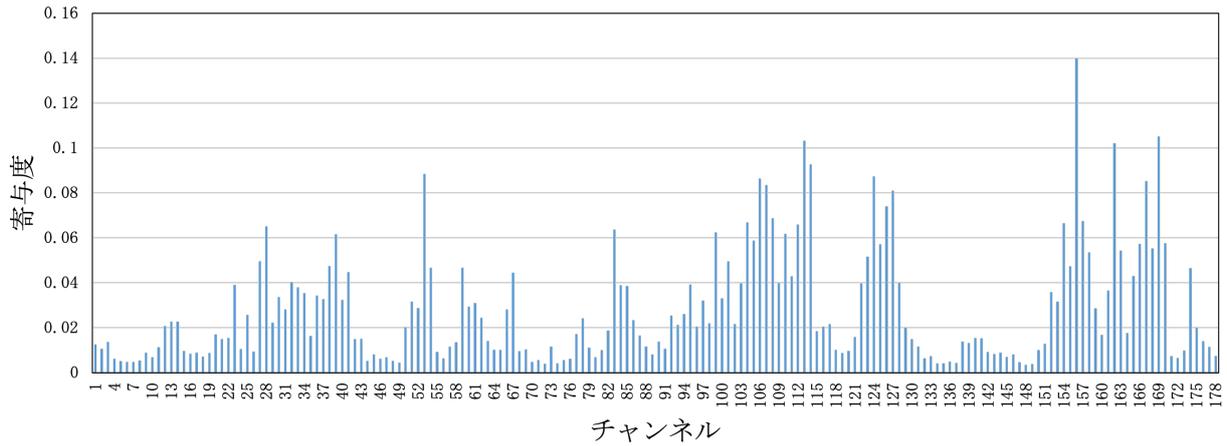


図 6 各チャンネルの寄与度 (RF によるモデル)

ネルにチャンネル数を削減し、モデルの構築を行った。前節で構築した、データ前処理後 RF を用いたモデルの各チャンネルの寄与度を算出した。図 6 に寄与度を示す。K 平均法を用いて 178 チャンネルを 30 のグループにクラスタリングした。表 3 に結果を示す。

表 3 30 グループのクラスタリングの結果

グループ	チャンネル
1	1, 2, 3, 4, 5, 6, 7
2	8, 9, 10, 11, 12
3	13, 14, 15, 16, 17
4	18, 19, 20, 21, 22
5	23, 24, 25, 26, 27, 28, 29
6	30, 31, 32, 33, 34
7	35, 36, 37, 38, 39
8	40, 41, 42, 43, 44, 45, 46
9	47, 48, 49, 50, 51, 52
10	53, 54, 55, 56, 57, 58
11	59, 60, 61, 62, 63
12	64, 65, 66, 67, 68
13	69, 70, 71, 72, 73, 74
14	75, 76, 77, 78, 79, 80, 81
15	82, 83, 84, 85, 86
16	87, 88, 89, 90, 91
17	92, 93, 94, 95, 96, 97
18	98, 99, 100, 101, 102, 103, 104
19	105, 106, 107, 108, 109, 110, 111, 112
20	113, 114, 115, 116, 117, 118, 119, 120, 121
21	122, 123, 124, 125, 126, 127
22	128, 129, 130, 131, 132
23	133, 134, 135, 136, 137, 138
24	139, 140, 141, 142, 143, 144
25	145, 146, 147, 148, 149
26	150, 151, 152, 153, 154
27	155, 156, 157, 158, 159
28	160, 161, 162, 163, 164
29	165, 166, 167, 168, 169, 170
30	171, 172, 173, 174, 175, 176, 177, 178

寄与度を用いた手法では算出した各チャンネルの寄与度のうち上位 30 チャンネルを使用することとした。そのため、チャンネル番号 28, 39, 53, 83, 99, 104, 105, 106, 107, 108, 110, 112, 113, 114, 123, 124, 125, 126, 127, 154, 156, 157, 158, 162, 163, 166, 167, 168, 169, 170 を使用した。またクラスタリングを用いた手法では、グループから 1 チャンネルを選ぶために、機械的に各グループのうち最も番号が若いものをグループの代表値として使用することとした。そのため、チャンネル番号 1, 8, 13, 18, 23, 30, 35, 40, 47, 53, 59, 64, 69, 75, 82, 87, 92, 98, 105, 113, 122, 128, 133, 139, 145, 150, 155, 160, 165, 171 を使用した。

図 7 に全チャンネルを使用したモデルとそれぞれの削減方法による 30 チャンネルを使用して RF を用いて構築したモデルの F1 score の比較を示す。

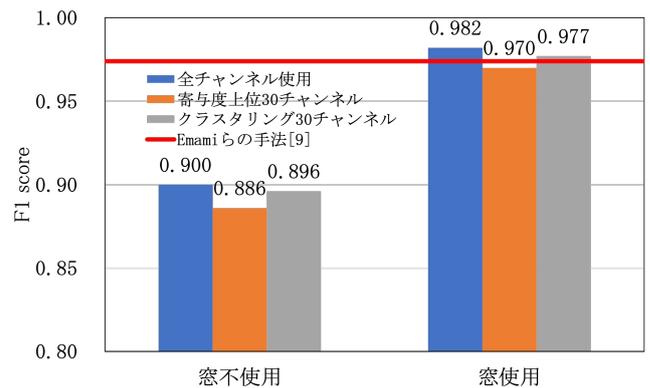


図 7 削減方法別モデルの比較 (F1 score)

図 7 中の赤線は Emami らの CNN による手法 [9] の F1 score を示す。また Recall では、窓使用後のデータを適用した場合、寄与度を用いた手法は 0.968、クラスタリングを用いた手法は 0.978 となった。寄与度を用いた手法に比べてクラスタリングを用いた手法の方が F1 score は優位な傾

向が見られ、チャンネル数の削減の影響が小さかった。また、寄与度を用いた手法は Emami らの手法 [9] の F1 score を下回った。このことから、クラスタリングを用いた手法でチャンネル数の下限を検討することとした。

チャンネル数を 30 に削減したときと同様の手法で、クラスタリングを用いてチャンネル数を 20, 15, 10 と削減した。図 8 にそれぞれのチャンネル数を使用して RF 及び KNN を用いて構築したモデルの F1 score の比較を示す。

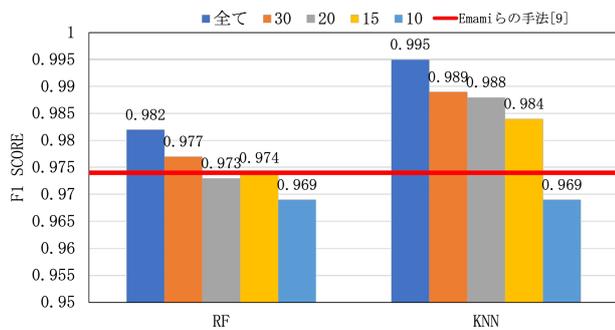


図 8 チャンネル数別モデル評価結果 (F1score)

図 7 と同様に、図 8 中の赤線は関連研究で用いられた CNN による手法の F1 score を示す。RF, KNN を用いて構築したモデルともチャンネル数を削減することで F1 score は低下したが、15 チャンネル以内であれば Emami らの手法 [9] 以上の F1 score を維持した。

## 6. おわりに

本稿では、てんかん発作時脳波識別モデルの構築と、それをもとにしたモデル構築に必要な脳波計のチャンネル数の削減を提案した。

スライド窓を用いたデータ前処理を行うことで行わない場合や Emami らの手法 [9] を適用した場合に比べて識別性能は向上し、KNN を用いて構築したモデルでは最高の F1 score : 0.995 を達成した。

チャンネル数の削減方法は、評価指標の値から、クラスタリングを用いた手法が寄与度を用いた手法より適していることを確認した。クラスタリングを用いた手法では 15 チャンネル以内であれば Emami らの手法 [9] 以上の F1 score を維持できることを確認した。

以上より、機械学習手法を適用したてんかん発作時脳波識別モデルを用いて、てんかん発作の識別に関して医師の診断の補助が可能なこと、またヘッドセット型の脳波計のような自宅で容易に脳波を計測できる機器を用いたてんかんの識別が可能なことを示した。

## 参考文献

[1] 厚生労働省:てんかんとは, 厚生労働省(オンライン), 入手先 (<https://www.mhlw.go.jp/kokoro/know/disease/epilepsy>

.html) (参照 2022-01-27).  
 [2] 公益社団法人日本てんかん協会:てんかんについて, 公益社団法人日本てんかん協会(オンライン), 入手先 (<https://www.jea-net.jp/epilepsy>) (参照 2022-01-27).  
 [3] 国立研究開発法人国立精神・神経医療研究センター:てんかん地域診療連携体制整備事業 2020 年度 全国拠点機関報告書, 国立研究開発法人国立精神・神経医療研究センター(オンライン), 入手先 ([https://www.ncnp.go.jp/epilepsy\\_center/pdf/report\\_r2.pdf](https://www.ncnp.go.jp/epilepsy_center/pdf/report_r2.pdf)) (参照 2022-01-27).  
 [4] 西田拓司, てんかん診療の現状と課題, 精神神経学雑誌, Vol.114, No.8, pp.957-959, 2012.  
 [5] WHO:Epilepsy, World Health Organization (online), 入手先 (<https://www.who.int/news-room/factsheets/detail/epilepsy>) (参照 2022-01-27).  
 [6] 独立行政法人国立病院機構静岡てんかん・神経医療センター:てんかん情報センター (2019), 独立行政法人国立病院機構静岡てんかん・神経医療センター(オンライン), 入手先 (<https://shizuokamind.hosp.go.jp/epilepsy-info/news/n4-3/>) (参照 2022-01-27).  
 [7] Khaled Mohamad Almustafa. Classification of epileptic seizure dataset using different machine learning algorithms. *Informatics in Medicine Unlocked*, Vol. 21, p. 100444, 2020.  
 [8] Mengni Zhou, Cheng Tian, Rui Cao, Bin Wang, Yan Niu, Ting Hu, Hao Guo, and Jie Xiang. Epileptic seizure detection based on eeg signals and cnn. *Frontiers in Neuroinformatics*, Vol. 12, p. 95, 2018.  
 [9] Ali Emami, Naoto Kunii, Takeshi Matsuo, Takashi Shinozaki, Kensuke Kawai, and Hirokazu Takahashi. Seizure detection by convolutional neural network-based analysis of scalp electroencephalography plot images. *NeuroImage: Clinical*, 2019.  
 [10] Irvine University of California : Epileptic seizure recognition data set, Irvine University of California(online), 入手先 (<https://archive.ics.uci.edu/ml/datasets/Epileptic+Seizure+Recognition>) (参照 2022-01-27).  
 [11] Breiman L, Random Forests. *Machine Learning*, 45, pp. 5-32, 2001.  
 [12] Altman, Naomi S. An introduction to kernel and nearest-neighbor nonparametric regression. *The American Statistician*, 46(3), pp.175-185, 1992.  
 [13] Jill C. Stoltzfus. Logistic regression: A brief primer. *Academic emergency medicine*, Vol. 18, No. 10, pp. 1099-1104, 2011.  
 [14] 日本臨床神経生理学会 ベーパレス脳波の記録・判読指針小委員会, デジタル脳波の記録・判読指針, 臨床神経生理学, 43 巻, 1 号, pp. 22-62, 2015.