

修士論文

心電図を用いた不整脈自動分類における 半教師あり・教師なし深層学習手法の有効性検証

川崎 聡大

奈良先端科学技術大学院大学

先端科学技術研究科

データサイエンスプログラム

主指導教員: 金谷 重彦 教授

計算システムズ生物学研究室 (情報科学領域)

令和2年 3月 6日提出

本論文は奈良先端科学技術大学院大学先端科学技術研究科に
修士(工学) 授与の要件として提出した修士論文である。

川崎 聡大

審査委員：

金谷 重彦 教授	(主指導教員, 情報科学領域)
笠原 正治 教授	(副指導教員, 情報科学領域)
峠 隆之 准教授	(副指導教員, バイオサイエンス領域)
黄 銘 助教	(副指導教員, 情報科学領域)

心電図を用いた不整脈自動分類における 半教師あり・教師なし深層学習手法の有効性検証*

川崎 聡大

内容梗概

一過性の不整脈に対して診断を行う場合は、ホルター心電図測定などの長期的な心電図測定が行われることが多い。被測定者は、小型のホルター心電図計を用いて家庭での長期測定を行う。測定後に医師が目視による診断を行うが、測定時間は24時間を超えるため、それらの診断には大きな負担が伴う。近年では、機械学習を用いて自動で不整脈を検出する研究が盛んに行われている。しかし、それらの多くは教師あり学習に基づくものであり、学習に用いる教師ラベルの作成には膨大な手間やコストが必要であるという課題がある。本研究では、半教師あり学習および教師なし学習による、不整脈分類およびクラスタリングを行い、これらの手法が教師ラベル作成支援へと有効であるかを検証した。その結果、半教師あり学習の検証では、少数の教師ありデータでの学習において、教師あり学習よりも高い精度の分類が可能であることがわかった。また、教師なし学習の検証では、そのクラスタリング結果がデータの教師ラベルクラスを反映したものとなり、ラベル作成支援や診断支援へと応用できる可能性が示唆された。さらに、心電波形データに対して、データの増大手法を適用し、少数データを増強する試みを行なった。これらから新規に増強・生成されたデータの不整脈自動分類への利用可能性について議論を行なった。

キーワード

不整脈, アノテーション支援, データ増強, 生成モデル, クラスタリング

*奈良先端科学技術大学院大学 先端科学技術研究科 修士論文, 令和 2年 3月 6日.

Semi-supervised and Unsupervised Learning for Arrhythmia Detection Using Electrocardiogram*

Toshihiro Kawasaki

Abstract

Holter electrocardiogram (Holter ECG), an instrument for long-term ECG measurement over 24 hours, is useful to discover transient arrhythmias that occur infrequently and therefore could not be seen in short-term measurement. Along with the development of machine learning, its application to automatic arrhythmia detection has been expected to reduce doctors' workload on diagnosis for Holter ECG. Although some studies using supervised learning methods such as CNN and RNN have reported that these models could reach high accuracy performance, insufficient labeled data is the bottleneck on identification of the signal of Holter ECG data. In this study, the author conducted experiments to examine the performance of semi-supervised methods and unsupervised methods in ECG classification. In the results, the author found that the semi-supervised model could classify arrhythmia more accurately than the supervised manner using a few labeled data. Moreover, the author have found that unsupervised model was able to make meaningful clusters. The findings of this study contribute to assist doctors' diagnosis or ECG annotation. In addition, the author proposed a generative model to augment the minorities in arrhythmic classes. This study will yield critical insights that will help facilitate the development of automatic arrhythmia detection.

Keywords:

arrhythmia, annotation support, data augmentation, generative model, clustering

*Master's Thesis, Graduate School of Science and Technology, Nara Institute of Science and Technology, March 6, 2020.

目次

図目次.....	V
第1章 序論.....	1
1.1 社会的な背景.....	1
1.2 心電図.....	1
1.2.1 心臓の構造.....	1
1.2.2 心電図の基本波形.....	2
1.2.3 不整脈.....	2
1.3 不整脈の自動検出・分類.....	3
1.4 課題・目的および本研究の取り組み.....	4
1.4.1 課題.....	4
1.4.2 目的.....	5
1.4.3 本研究の取り組み.....	5
第2章 データセット.....	7
2.1 概要.....	7
2.2 データの整形・前処理（共通）.....	7
2.2.1 心電図セグメントの再アノテーションおよび教師ラベルの概要.....	8
2.2.2 アンダーサンプリング.....	10
第3章 半教師あり学習.....	11
3.1 手法.....	11
3.1.1 <i>Virtual Adversarial Training</i>	11
3.1.2 <i>Entropy Minimization</i>	14
3.2 実験方法.....	14
3.3 結果・考察.....	16
3.4 半教師あり学習 まとめ.....	24
第4章 DATA AUGMENTATION.....	25
4.1 手法.....	25
4.1.1 <i>Autoencoder</i>	25
4.1.2 <i>Variational Autoencoder</i>	27
4.2 実験.....	30
4.2.1 <i>Convolutional Autoencoder</i> による心電波形の再構築.....	30
4.2.1.1 実験方法.....	30

4.2.1.2	心電波形の再構築結果・考察.....	31
4.2.2	<i>Variational Autoencoder</i> による心電波形生成.....	34
4.2.2.1	実験方法.....	34
4.2.2.2	結果.....	35
4.2.2.2.1	VAEによる心電波形の再構築結果・考察.....	35
4.2.2.2.2	VAEによる心電波形の生成結果・考察.....	38
4.3	DATA AUGMENTATION まとめ.....	40
第5章	教師なしクラスタリング.....	41
5.1	手法.....	41
5.1.1	<i>Information Maximizing Self-Augmented Training (IMSAT)</i>	41
5.1.2	<i>Regularized Information Maximization (RIM)</i>	41
5.1.3	<i>Self-Augmented Training (SAT)</i>	42
5.2	実験方法.....	42
5.3	結果・考察.....	43
5.4	教師なしクラスタリング まとめ.....	53
第6章	総括.....	54
	謝辞.....	55
	参考文献.....	56

図目次

図 1.1 心臓の構造および刺激伝導系の概要図（参考文献 [5] より引用）	2
図 1.2 正常な心電図の基本波形（参考文献 [5] より引用）	2
図 2.1 ビートアノテーションおよびリズムアノテーションの概要図.....	7
図 3.1 半教師あり学習における心電波形分類の混同行列（1）	17
図 3.2 半教師あり学習における心電波形分類の混同行列（2）	18
図 3.3 教師あり学習における心電波形分類の混同行列（1）	19
図 3.4 教師あり学習における心電波形分類の混同行列（2）	20
図 3.5 半教師あり学習および教師あり学習における Precision の値.....	22
図 3.6 半教師あり学習および教師あり学習における Recall の値.....	22
図 3.7 半教師あり学習および教師あり学習における F1 の値.....	22
図 4.1 Autoencoder のネットワーク構造.....	26
図 4.2 VAE の概要図.....	27
図 4.3 実験で用いた CAE のネットワーク構造.....	30
図 4.4 CAE による心電波形再構築の結果の例（クラス：N）	32
図 4.5 CAE による心電波形再構築の結果の例（クラス：AF）	32
図 4.6 CAE による心電波形再構築の結果の例（クラス：VT）	33
図 4.7 CAE による心電波形再構築の結果の例（クラス：VF）	33
図 4.8 実験で用いた VAE のネットワーク構造.....	34
図 4.9 VAE による心電波形再構築の結果の例（クラス：N）	36
図 4.10 VAE による心電波形再構築の結果の例（クラス：AF）	36
図 4.11 VAE による心電波形再構築の結果の例（クラス：VT）	37
図 4.12 VAE による心電波形再構築の結果の例（クラス：VF）	37
図 4.13 VAE による心電波形生成の結果の例.....	39

図 5.1 IMSAT による心電波形画像のクラスタリング結果 (K=2)	44
図 5.2 IMSAT による心電波形画像のクラスタリング結果 (K=3)	44
図 5.3 IMSAT による心電波形画像のクラスタリング結果 (K=4)	45
図 5.4 IMSAT による心電波形画像のクラスタリング結果 (K=5)	45
図 5.5 IMSAT による心電波形画像のクラスタリング結果 (K=6)	46
図 5.6 IMSAT による心電波形画像のクラスタリング結果 (K=7)	46
図 5.7 IMSAT による心電波形画像のクラスタリング結果 (K=8)	47
図 5.8 IMSAT による心電波形画像のクラスタリング結果 (K=9)	47
図 5.9 IMSAT による心電波形画像のクラスタリング結果 (K=10)	48
図 5.10 K=2 においてクラスター0 に含まれる N・AF ラベルの心電波形画像の例	48
図 5.11 K=3 におけるクラスター0 とクラスター2 の N ラベルの比較 (1)	49
図 5.12 K=3 におけるクラスター0 とクラスター2 の N ラベルの比較 (2)	49
図 5.13 K=3 におけるクラスター0 とクラスター2 の AF ラベルの比較	50
図 5.14 K=3 におけるクラスター1 とクラスター2 の VF ラベルの比較	50
図 5.15 心電波形信号に対するクラスタリング結果 (K=8)	53

第 1 章 序論

1.1 社会的な背景

厚生労働省の発表によると、平成 29 年における日本の死因順位において、心疾患は悪性新生物に次いで第 2 位となっている [1]。また、WHO (World Health Organization) の発表においては、2016 年時点での世界の死亡原因第 1 位は、虚血性心疾患である [2]。これらから、心疾患についての課題は、国内だけでなく世界においても重要なテーマであることが分かる。それに加え、日本では高齢化による医療費の増大が問題視されている。厚生労働省によれば、日本の医療費は年々増大しており、平成 29 年度では 43 兆 710 億円に達している [3]。これは、10 年前と比較すると、9 兆円近く医療費が増加していることになる。

心疾患の予防や早期発見は、それらの疾患による死者数の減少や、医療費の削減に繋がると考えられる。近年では、家庭での簡易な心電図測定を可能とする様々なデバイスが開発されている。例えば、小型の電極棒を数分握るだけで心電図測定が行え、その結果をタブレット端末で確認できるものや、腕時計型の測定装置などである。これらのデバイスを活用することにより、病院へ行く手間や費用を削減することができる。また、高頻度かつ手軽に定期検査が可能であることから、心疾患の予防や早期発見に繋がると思われる。

ただし、これらの端末で問題となるのは、診断結果の正確性・信憑性である。簡易な測定であることに加え、医師を直接通さず検査を行うため、高性能な心電波形自動分類手法が必要となる。近年の機械学習手法の発展に伴い、それらの手法が心電波形の自動分類手法の高性能化へも寄与し始めている。本研究は、機械学習手法による心電波形自動分類に係る課題に対し、解決策を提案するものである。

1.2 心電図

心電波形の自動分類手法について言及する前に、心臓および心電図に関する基本的な知識について整理する。

1.2.1 心臓の構造

心臓は、周期的に収縮・拡張を行うことで全身へと血液を循環させる。この周期的な運動は、心筋細胞の膜電位の変動による周期的な電気信号に伴い発生している。この微弱な電気信号を体表面の電極等から検出、増幅し波形として記録したものが心電図である [4]。図 1.1 に心臓の構造および刺激伝導系の概要図を示す。心臓は、心腔と呼ばれる 4 つの空洞を有しており、それらはそれぞれ右心房、左心房、右心室、左心室と呼ばれる (図 1.1 の a)。微弱な電気信号は、右心房にある洞結節という部位を起点に、自

動的に発せられており、房室結節を通して左心房側へと伝導する。この電気信号の伝導過程を刺激伝導系とよぶ (図 1.1 の b)。

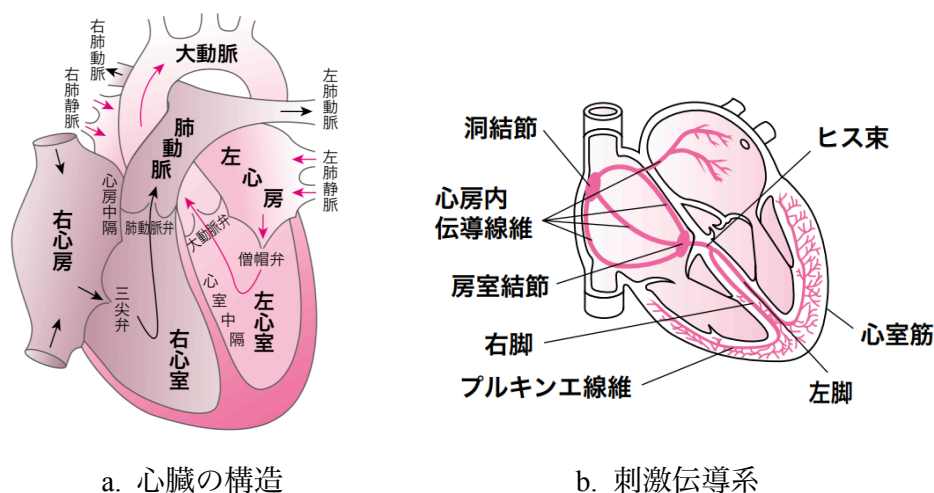


図 1.1 心臓の構造および刺激伝導系の概要図 (参考文献 [5] より引用)

1.2.2 心電図の基本波形

図 1.2 に正常な心電図の基本波形を示す。波形内の各ピークにはそれぞれ名前が付けられており、図 1.2 に示すように左から順に P 波、QRS 波、T 波、U 波とよばれる。また、電気信号による心臓部位の興奮との対応は、P 波が心房の興奮、QRS 波が心室の興奮、T 波が心室の興奮の消退となっている。U 波は未だに成因が不明であり、心臓部位の興奮とは対応づけがとられていない。




図 1.2 正常な心電図の基本波形 (参考文献 [5] より引用)

1.2.3 不整脈

本研究で取り扱う不整脈について述べる。正常な心拍リズム以外の異常なりズムを総称して不整脈という。数多く存在する不整脈のうち本研究では、心房細動 (atrial fibrillation; AF), 心室頻拍 (ventricular tachycardia; VT), 心室細動 (ventricular fibrillation;

VF) を取り扱う。

心房細動は、心房が小刻みに震え、心房全体の収縮がなくなってしまう不整脈である。心房内に血液が滞留するため、血栓が生じやすく、脳や全身の臓器における血流の遮断の原因となる。心房内で電気信号が正常に伝導されないため、心電波形内の P 波の消失がおきる。また、心房からの電氣的信号が乱れるために、心室の規則的な興奮が崩れ、R 波と R 波の間隔である RR 間隔の周期性が失われる。

心室頻拍は、心室において生じる頻拍であり、脈拍が異常に早くなる。血液を全身へと送り出す能力が低下するため、非常に危険な状態である。心電波形は、P 波が消失し、QRS 波の幅が広くなる。波形の周期には規則性がみられる。

心室細動は、心室が拍動せずに小刻みに震える不整脈である。心室が小刻みに震えるだけで、血液を送り出す役割を果たしていないため、意識消失がおき、適切に処置をしない場合は、数分で死に至る致命的な不整脈である。心電波形に規則性がなくなり、P 波、QRS 波、T 波の識別は困難である。

1.3 不整脈の自動検出・分類

不整脈の中には、通院時の短時間の心電図測定では検出が難しいものもある。ホルター心電図検査は、24 時間や 48 時間などの長期的・連続的な心電図測定に用いられ、短時間測定では検出の難しい不整脈を検出するのに役立つ。通常、ホルター心電図を用いた診断は、心電図の測定後に医師が目視で行う。この際に、HR (heart rate : 1 分あたりの心拍数) や ST レベル (S 波から T 波にかけての波形部分の高低) などの変動が、測定機器に搭載された自動解析ツールなどにより、自動解析結果として表示される。医師は、これらの自動解析結果を心電波形と照らし合わせながら診断を行う。しかし、ホルター心電図検査で得られる心電図は、24 時間を超える長期的なものであるため、波形を見ながらの診断は医師に膨大な負担をかける。

また、家庭や個人での健康のセルフケアとしての心電図測定においては、小型の簡易的な心電装置や心電測定機能が搭載されたスマートウォッチ・タブレットなどのデバイスが活用される。これらのデバイスを活用する場合、デバイス内に搭載された自動診断ツールによって不整脈の診断が行われる。医師が直接診断するわけではないため診断結果の正確性に不安が残るものの、これらのデバイスの活用は心疾患の早期発見に極めて有用である。ゆえに、心電図測定デバイスに搭載された不整脈自動検出ツールの正確性向上が期待される。

近年の機械学習の発展に伴い、心電図診断における医師の負担軽減や、家庭用心電図測定デバイスの性能向上といった課題に対しても、これらの手法が取り入れられるようになった。機械学習を用いて心電波形から不整脈を検出・分類する際には、前処理として、心電図波形のセグメンテーションや特徴量抽出を行う。セグメンテーションでは、心電図波形全体から 1 周期の心電波形を切り出すために、R 波の検出や QRS 波の検出を

自動で行い、心電波形セグメント内での R 波の位置補正などを行う場合がある。R 波の検出や QRS 波の自動検出には、Matched Filter [6] などの手法が用いられる。また、心電波形の特徴量抽出としては、フーリエ変換やウェーブレット変換などの周波数解析手法などが用いられる。ウェーブレット変換が R 波、QRS 波などの検出に用いられる場合もある [7]。しかし、前処理時に R 波などの検出を行う場合は、心電波形内に R 波が存在している必要がある。不整脈の種類によっては、R 波が消失している場合もあるため、これらの不整脈の検出・分類を行う場合には、R 波検出などの処理を伴う手法では対処が難しい。これに対し、畳み込みニューラルネットワーク (Convolutional Neural Network; CNN) などの深層機械学習手法を用いた方法においては、R 波検出などを伴う処理が不要となり、学習モデルが特徴量抽出を自動で行うことができる。この場合には、R 波の位置に依存しないため、任意の時間間隔でセグメンテーションを行なった心電波形データに対しても、有効な不整脈検出・分類が行える。このため近年では、深層機械学習を用いた心電波形自動分類手法が発展してきている。例えば、再帰的ニューラルネットワーク (Recurrent Neural Network; RNN) を用いて心電図の不整脈分類を行う試み [8] や、CNN と RNN を組み合わせて分類を行う [9] などの試みがある。また、CNN を使った学習モデルが医師の診断精度を上回るなどの報告 [10] もされている。これらの事例から、深層機械学習が心電図解析の発展に大きく寄与していることがわかる。

機械学習手法が不整脈の自動検出・分類に極めて有効であることを示したが、一方で、これらの手法は大量の教師付きデータに依存したものである。すなわち、これらの機械学習手法は、学習の際に心電波形データに対応する教師ラベル (正常波形かあるいは、いずれの不整脈かを示す情報) が必要である。データサンプルのそれぞれに教師ラベルを必要とする機械学習手法を教師あり学習とよぶ。また、教師ラベルなどの情報を心電図データへと対応付ける作業をアノテーションとよぶ。アノテーション済みのデータが少数の場合は、教師あり学習では十分な性能を得られない可能性が高い。よって、教師あり学習を用いて不整脈分類を行うには、事前に教師ラベルなしのデータに対してアノテーション作業を行い、十分な教師ありデータを用意する必要がある。通常は、医師などの専門家がこのアノテーションを行うが、用意すべきデータは膨大である場合が多く、アノテーション作業にとって大きな負担となる。また、アノテーションにかかる時間や人件費などの費用も問題となる。

1.4 課題・目的および本研究の取り組み

本研究で取り扱う課題や目的について整理し、それらに対する解決策の概要について述べる。

1.4.1 課題

本研究において想定する前提条件および課題は次のとおりである。

(1) 前提条件

- 長期的な心電図検査によって得られた心電波形データがある。
- 教師ラベルが付与されたデータが少数であり，ほとんどのデータに対してアノテーションが行われていない。

(2) 課題

- 長期心電図検査における不整脈診断は，医師に大きな負担を与える。
- 診断の自動化を行う場合，教師あり学習では十分な性能が得られない。
- 多大なアノテーション作業が必要である。
- アノテーション作業の人的，経済的な負担が大きい。

1.4.2 目的

本研究の目的は，以下のとおりである。

- 心電波形データに対するアノテーションの補助
- 不整脈診断の支援

1.4.3 本研究の取り組み

教師ラベルの付与されたデータが少ない場合であっても，心電波形の教師ラベルクラス（正常あるいは不整脈の種類を示すクラス）を自動的に識別し，その教師ラベルクラスを医師あるいはアノテーション作業員へと補足的に提示できるようなシステムを目指す。これにより，見分けが難しい不整脈に対するアノテーションあるいは診断において，いずれの教師ラベルクラス・不整脈であるかを素早く判断できたり，アノテーションや診断の間違いが減るなどの効果が期待できる。

本研究では，半教師あり深層学習による，教師ラベルクラス分類手法を提案した。半教師あり学習とは，機械学習手法のうちの一つであり，データ全体中の一部のみに教師ラベルが付与されたデータセットに対しても学習を行うことができる手法である。心電波形データに対して半教師あり学習を適用した事例は少なく，その有効性が明確でない。よって，本研究では，半教師あり学習が心電波形データのアノテーション補助や診断補助へと活用可能か否かを検証・考察した。

また，半教師あり学習の性能を向上させるため，Data Augmentation（データの水増し）についても取り組む。心電図は，個人による違いが大きい。そのため，データ数が少ない場合，モデルの学習時に特定の被験者の心電波形データを過学習してしまう可能性が高い。そこで，本研究では生成モデルを用いた Data Augmentation について実験を行った。生成モデルとは，データの確率分布を学習することで，その確率分布から新規の

データを生成することができる機械学習モデルである。生成モデルを用いてデータを新たに生成することで、心電図の波形に多様性が増え、より頑健な不整脈検知・分類モデルが構築できると考えられる。

さらに本研究では、教師ラベルが全く無い場合の不整脈検出・分類にも取り組んだ。教師ラベルを全く使わずに行う機械学習を教師なし学習とよぶ。教師なし学習によって、心電波形の特徴ごとのグループ分けを行う。このグループ分けを教師なしクラスタリングとよび、クラスタリングによって得られるグループをクラスターとよぶ。教師なしクラスタリングは、教師ラベルに依存しないため、今まで発見できなかったような新規のクラスターを得られる場合がある。これらの新規クラスターから得られる新たな知見は、不整脈検出・分類モデルに与える特徴量へと反映することで、それらの性能向上にも役立てられる可能性をもつ。また、教師なしクラスタリングをした場合、通常は教師ラベルクラスごとにクラスターが形成される傾向にある。その際に、教師ラベルクラスごとに、明確にクラスターが分かれる場合、教師なしクラスタリングモデルそのものを不整脈検出・分類モデルとして活用できる。本研究では、教師なし深層学習モデルを用いて心電波形のクラスタリングを行なった。

第2章 データセット

2.1 概要

本研究ではデータセットとして、PhysioNet [11] において公開されているデータベース MIT-BIH arrhythmia database (MITDB) [12] および MIT-BIH Malignant Ventricular Ectopy Database (VFDB) [13] に登録された心電図レコードを用いた。

MITDB は、47 人の被験者の 24 時間ホルター心電図から、30 分の心電波形を抽出した、全部で 48 レコードのデータセットである。波形のサンプリング周波数は 360Hz である。被験者 47 名のうち、男性は 32 歳から 89 歳までの 25 名、女性は 23 歳から 89 歳までの 22 名である。各心電波形レコードには、その心電波形が正常か異常か、異常の場合はどの種類の不整脈かを示すアノテーションが施されている。波形 1 周期ごとのアノテーション (ビートアノテーション) と波形の変化ごとのアノテーション (リズムアノテーション) の 2 種類のアノテーションが存在し、MITDB では両方のアノテーションが施されている。図 2.1 にビートアノテーションおよびリズムアノテーションの概要図を示す。

VFDB は、22 人の被験者のホルター心電図から、30 分の波形を抽出した全部で 22 レコードのデータセットである。心電波形のサンプリング周波数は 250Hz である。各心電図波形サンプルには、リズムアノテーションが施されている。

どちらのデータベースの心電図についても、第 II 誘導 (左足右手間での測定) の心電波形を用いて実験を行なった。




図 2.1 ビートアノテーションおよびリズムアノテーションの概要図

2.2 データの整形・前処理 (共通)

本研究で行う実験において共通して施されるデータの整形・前処理について述べる。

2.1 節で述べたデータベース MITDB および VFDB において、データベースに登録されている心電図レコードそれぞれに対して次の処理を行った。

- (1) MITDB においてのみサンプリング周波数を 250Hz へとリサンプリングする。
- (2) 心電波形の両端 60 秒間の波形を除去する。
- (3) 心電波形を 3 秒ごとに区切り、それぞれを心電図セグメントと呼ぶ。

- (4) 心電図セグメントに対する再アノテーション (2.2.1 節において詳しく述べる) を行い, 本研究ではこのアノテーション結果を教師ラベルとして扱う.
- (5) 教師ラベルクラスが N, AF, VT, VF (2.2.1 節を参照) である心電図セグメントを抽出する. (よって, 本研究で用いる教師ラベルのクラス数は 4 となる.)
- (6) 周波数帯域 0.1Hz~40Hz のバンドパスフィルタリングを行う.
- (7) 各ラベルごとの心電図セグメント数の上限が 1700 になるようにアンダーサンプリング (2.2.2 節において詳しく述べる) を行う.

以上の処理により, 心電図セグメント数は 5850 となった. 各心電図セグメントは N, AF, VT, VF のいずれか 1 つの教師ラベルクラスをもつ. 教師ラベルクラスごとのセグメント数は N が 1,700, AF が 1,700, VT が 1,692, VF が 758 となった. 各データのセグメント長は, $250[\text{Hz}] * 3[\text{秒}] = 750$ である. また, データセットを訓練データセットとテストデータセットに分割した. 分割後のセグメント数は, 訓練データが 4,680, テストデータが 1,170 である.

2.2.1 心電図セグメントの再アノテーションおよび教師ラベルの概要

再アノテーションは, 本節で述べる (i) ・ (ii) の処理 (1 段階目) および教師ラベルの統一化 (2 段階目) の 2 段階で行われる.

まずは 1 段階目の処理について述べる. 本研究では, 心電波形を連続的に 3 秒ごとの心電図セグメントへと分割しているため, 1 つの心電図セグメントに対して, 複数のラベル情報が混在している場合がある. 例えば, MITDB においては, 心電波形 1 拍動ごとにビートアノテーションが施されているため, 3 秒ごとに波形を分割すると, ほとんどの場合で 3 拍動以上の波形を含み, 正常波形と異常波形が混在する場合がある. そのため, 心電図セグメントの教師ラベルクラスとしてどちらを採用するか決める必要がある. 1 つの心電図セグメントに対し, 1 つの教師ラベルクラスを対応させるため, 心電図セグメントに対して以下に示す (i) ・ (ii) の処理のいずれかを適用する.

(i) MITDB から抽出した心電図セグメントの場合

MITDB にはビートアノテーションとリズムアノテーションの 2 種類のアノテーションが施されているため, 両方を考慮して再アノテーションを行う. 再アノテーションを行う際の規則を以下に示す.

規則1: 心電図セグメント内にリズム変化を含む場合, その心電図セグメントをデータセットから除外する.

規則2: 心電図セグメントにおいて, リズムアノテーションが正常ラベルにも関わらず, ビートアノテーションが不整脈などの異常ラベルを含む場合は, 最も多

く含むビートアノテーションの異常ラベルクラスを、その心電図セグメントの教師ラベルクラスとする。

規則3：上記二つの規則のいずれにも当てはまらない場合は、リズムアノテーションを教師ラベルクラスとする。

ただし、規則2において、複数種類の異常ラベルクラスを同数だけ含むものは存在しなかったため、異常ラベルの多数決によって、教師ラベルクラスは一意に決まることに注意されたい。

(ii) VFDB から抽出した心電図セグメントの場合

VFDB にはリズムアノテーションのみが施されているため、再アノテーションはリズムアノテーションのみを考慮する。(i) MITDB の場合で示した規則1をVFDBにも適用し、それ以外の場合は、リズムアノテーションを教師ラベルクラスとする。

教師ラベルの統一化(2段階目)の処理について述べる。リズムアノテーションおよび、ビートアノテーションでは同じ疾患に対して、アノテーションの表記の仕方(記号)が異なる。また、リズムアノテーション内で、同じ種類の疾患を別表記で表している場合もある。そのため、本研究で用いる正常波形および不整脈のアノテーション記号を統一する必要がある。本研究で用いる教師ラベルクラスの概要を表2.1に示す。表2.1の左端列が本研究で用いた教師ラベルクラスであり、元のアノテーション表記は第2列に示されている。上記(i)・(ii)の処理で得られた心電図セグメントに対して、該当する心電図セグメントの教師ラベル表記をN, AF, VT, VFへと変換し、同種の不整脈に対する教師ラベルの表記を統一した。

表 2.1 教師ラベルクラスの概要

教師ラベルクラス	ビートアノテーション またはリズムアノテーションにおける表記	名称	説明
N	N, (N, (NSR	正常	正常な心電波形
AF	(AFIB	心房細動	心房性の不整脈。心房が細かく震え、脈が不規則になる。心電波形では、P波の消失などがみられる。
VT	(VT	心室頻拍	心室性の不整脈。通常の発生源とは異なる箇所からの電気刺激により、脈拍の高い状態になる。
VF	(VF, (VFIB	心室細動	心室性の不整脈。心室が細かく震え、血液を全身へと送ることが困難である状態。

2.2.2 アンダーサンプリング

一般に、教師ラベルクラス間におけるデータ数の不均衡は予測モデルの学習を妨げ、性能低下を招く場合がある。これは、データ内に多く含まれる教師ラベルクラスのデータを他のラベルクラスデータよりも多く学習してしまい、前者のラベルデータに有利な学習を行ってしまうためである。本研究で用いるデータセットにおいても再アノテーション後で、教師ラベルクラス間にデータ数の偏りが生じていた。具体的には、N (正常) のデータ数が 12,786、AF (心房細動) が 3,440、VT (心室頻拍) が 1,692、VF (心室細動) が 758 であり、N が他と比べて極めて多かった。データ不均衡問題に対する解決策の一つとして、アンダーサンプリングと呼ばれる手法がある [14]。これは、任意の規則により、データ数の大きいラベルデータの一部を学習時に取り除き、データ数の小さいラベルデータへとデータ数を近づける手法である。アンダーサンプリング手法の一つであるランダムアンダーサンプリングでは、データを取り除く際にデータ数の大きいラベルのデータをランダムに抽出・除外することで、アンダーサンプリングを行う。本研究では、学習の不平等性の防止およびデータ数削減による学習コストの低下を期待し、ランダムアンダーサンプリングをデータセットへと適用した。

第3章 半教師あり学習

本研究の目的は、「心電波形のアノテーション支援」および「不整脈診断の支援」である。これに対する施策として、機械学習手法の一つである半教師あり学習の利用を提案する。本章では半教師あり学習手法である Virtual Adversarial Training (VAT) [15][16] および Entropy Minimization [17] について述べ、その有効性について検証・考察を行う。

3.1 手法

本研究では、Virtual Adversarial Training (VAT) および Entropy Minimization を用いて、半教師あり学習による心電波形の自動分類を行なった。VAT と Entropy Minimization は、それぞれ独立に半教師あり学習手法として用いることができるが、これら二つを組み合わせると性能が向上することが示唆されている [18]。そこで、本研究においてもこれら二つの手法の組み合わせを用いることにした。

本節では、VAT および Entropy Minimization のそれぞれの手法について詳細を述べる。

3.1.1 Virtual Adversarial Training

Virtual Adversarial Training (VAT) は、分類モデルの頑健性を高めるための正則化手法の一つである。VAT を用いた半教師あり学習では、教師なしデータに対して VAT を適用することで、教師ありデータの情報に加えて、教師なしデータの情報をモデルの訓練に利用することができる。以下では、VAT の前身手法である Adversarial training [19] について述べた後、VAT について説明する。

入力データ x における損失関数の勾配に基づいた、人間の目では認識できない小さな摂動を r_{adv} とする。摂動 r_{adv} を入力データ x にノイズとして加えたデータ $x + r_{adv}$ を Adversarial example [20] とよぶ。分類モデルに Adversarial example を入力すると、人間の目では識別できないノイズであるにも関わらず、分類結果が大きく狂うことが知られている。Adversarial training は、モデルの訓練時に Adversarial example を入力データの一部とすることで、モデルの頑健性・汎化性を高める手法である。分類で用いるニューラルネットワークの損失関数を \mathcal{L} 、ネットワークの学習パラメータを θ 、教師ラベルを目的変数 y ($y \in Q$)、損失関数に対する入力 x の勾配を ∇_x 、ハイパーパラメータを ε とすると、Adversarial example で用いる摂動 r_{adv} は以下の式から生成される。

$$r_{adv} = \varepsilon \text{sign}(\nabla_x \mathcal{L}(\theta, x, y)) \quad (3.1.1)$$

Adversarial training における目的関数 $\tilde{\mathcal{L}}$ は、ハイパーパラメータを α とすると、以下のよう表せる。

$$\tilde{\mathcal{L}} = \alpha \mathcal{L}(\theta, x, y) + (1 - \alpha) \mathcal{L}(\theta, x + r_{adv}) \quad (3.1.2)$$

VAT は, Adversarial training を教師なし学習あるいは半教師あり学習へと適用できるように拡張したものである. VAT におけるネットワークの損失関数は, Adversarial training の損失関数 \mathcal{L} を \mathcal{L}_{vadv} , 摂動を r_{vadv} として以下のように表す.

$$\mathcal{L}_{vadv} = D[p(y|x, \theta) || p(y|x + r_{vadv}, \theta)] \quad (3.1.3)$$

$$\text{where } r_{vadv} = \arg \max D[p(y|x, \theta) || p(y|x + r, \theta)], \quad r; \|r\| \leq \varepsilon \quad (3.1.4)$$

ここで, $D[p || p']$ は二つの確率分布 p と p' との距離関数であり, r はガウス分布を用いて初期化される摂動である. 式 (3.1.3) は分類モデルによる予測確率分布 $p(y|x, \theta)$ と, 摂動 r_{vadv} を加えた時の予測分布 $p(y|x + r_{vadv}, \theta)$ との確率距離を表している. 距離関数として $D_{KL} := \text{KL-divergence}$ を用いる場合, 距離関数 D は,

$$\begin{aligned} D[p(y|x, \theta) || p(y|x + r, \theta)] &= D_{KL}[p(y|x, \theta) || p(y|x + r, \theta)] \\ &= - \sum_{y \in Q} p(y|x, \theta) \log \frac{p(y|x, \theta)}{p(y|x + r, \theta)} \end{aligned} \quad (3.1.5)$$

となる. また, 式 (3.1.4) は, 二つの確率分布が条件の範囲内で最大となるように摂動 r_{vadv} を求めている. すなわち, r_{vadv} は分類モデルの識別を最も狂わせるように生成される. 式 (3.1.4) において r_{vadv} は線形近似で求めることが困難である. これは, $r = 0$ において $D_{KL}[p(y|x, \theta) || p(y|x + r, \theta)]$ は常に 0 となり, 勾配が消失するためである. この問題に対処するために, 式変形による近似を行う. 表記を単純にするために $D_{KL}[p(y|x, \theta) || p(y|x + r, \theta)]$ を $D_{KL}(r, x, \theta)$ と置く. $D_{KL}(r, x, \theta)$ について $r = 0$ の周りでテイラー展開を行うと, 二次導関数までの近似式は以下のようなになる.

$$D_{KL}(r, x, \theta) \approx D_{KL}(0, x, \theta) + r^T \nabla_r D_{KL}(r, x, \theta)|_{r=0} + \frac{1}{2} r^T H(x, \theta) r \quad (3.1.6)$$

ただし, $H(x, \theta)$ は以下で定義されるヘッセ行列である.

$$H(x, \theta) := \nabla \nabla_r D_{KL}(r, x, \theta)|_{r=0} \quad (3.1.7)$$

$r = 0$ において $p(y|x, \theta) = p(y|x + r, \theta)$ であるから, $D_{KL}(0, x, \theta) = 0$ となる. この時, $\nabla_r D_{KL}(r, x, \theta)$ は最小値をとるため, $\nabla_r D_{KL}(r, x, \theta)|_{r=0} = 0$ になると考えられる. よって, 式 (3.1.6) は,

$$D_{KL}(r, x, \theta) \approx \frac{1}{2} r^T H(x, \theta) r \quad (3.1.8)$$

となる. $r^T H(x, \theta) r$ を最大化する r は, $H(x, \theta)$ の最大固有値に対する固有ベクトルである. これは, べき乗法 [21]を用いることで簡単に求めることができる. べき乗法は, ランダムに初期化した単位ベクトル d を用いて,

$$d \leftarrow \overline{H(x, \theta)d} \quad (3.1.9)$$

を繰り返し実行し, d を更新することで, $\overline{H(x, \theta)d}$ の最大固有値に対する固有ベクトルを求める方法である. また, $H(x, \theta)$ を直接計算することは困難であるため, 差分法を用いて $H(x, \theta)d$ を以下のように近似する.

$$\begin{aligned} H(x, \theta)d &\approx \frac{\nabla_r D_{KL}(r, x, \theta)|_{r=\xi d} - \nabla_r D_{KL}(r, x, \theta)|_{r=0}}{\xi} \\ &= \frac{\nabla_r D_{KL}(r, x, \theta)|_{r=\xi d}}{\xi} \end{aligned} \quad (3.1.10)$$

ξ は非ゼロのハイパーパラメータである. 右辺の分母の ξ は, d を正規化する際に消えるため無視することができる. よって, 更新式は以下ようになる.

$$d \leftarrow \overline{\nabla_r D_{KL}(r, x, \theta)|_{r=\xi d}} \quad (3.1.11)$$

べき乗法の更新回数については, 論文 [16] において, 更新回数1回で十分な精度を得られることが確認されている. よって, 本研究でも更新回数は1回とした. この条件下においては, 最終的な r_{vadv} は以下のように近似される.

$$r_{vadv} \approx \varepsilon \frac{g}{\|g\|_2} \quad (3.1.12)$$

$$\text{where } g = \nabla_r D_{KL}[p(y|x, \theta) || p(y|x+r, \theta)]|_{r=\xi d} \quad (3.1.13)$$

VATを用いた半教師あり学習においては, 教師なしデータに対して分類モデルの識別を最も狂わせる摂動 r_{vadv} を加えて学習を行うことで, モデルの正則化を行い, 学習の頑健性を高めることができる.

3.1.2 Entropy Minimization

Entropy Minimization [17] は、入力データ x と予測ラベル y との条件付きエントロピー (conditional entropy) を最小化することで、予測分布を尖らせ、分類モデルによって予測される教師なしデータのラベルの不確かさを最小化する手法である。本研究で用いる Entropy Minimization の損失関数 \mathcal{L}_{EntMin} は、教師なしデータ x に対する予測ラベルを y 、その予測分布を $p(y|x, \theta)$ とすると、以下のように定義される。

$$\mathcal{L}_{EntMin} = - \sum_y p(y|x, \theta) \log(p(y|x, \theta)) \quad (3.1.14)$$

この損失関数を最小化することによって、教師なしデータ x に対する予測ラベル y の予測分布間での重複が縮小するため、教師なしデータに付与されるラベルの不確かさが削減されることが期待できる。

3.2 実験方法

第2章で述べた 4,680 サンプルの訓練データに対し、VAT および Entropy Minimization による半教師あり学習をおこなった。また、1,170 サンプルのテストデータを用いて、分類モデルの性能評価を行なった。半教師学習における、教師ありデータの含有率と分類性能とを評価するために、各教師ラベルクラスのデータ数が均等になるように、教師ありのデータ数を 4~4,680 まで段階的に変動させながら学習を行い、それぞれの予測性能の評価を行なった。訓練データセットの中から、ランダムに教師ありデータを抽出し、抽出されなかった他の訓練データは、そのラベルを隠すことで教師なしデータとして扱った。本研究では、心電波形の分類器として、Deep Residual Network (ResNet50) [22] を用いた。ただし、各畳み込み層は全て 1 次元畳み込み層である。分類器の最終層 y における活性化関数は sigmoid 関数を用いた。sigmoid 関数は、教師ラベルのクラス数を K (本研究では $K = 4$)、各クラスを $c \in Q$ 、クラス c に属する確率を p_c とすると、以下のように定義される。

$$p_c = \frac{\exp(y_c)}{\sum_{c=1}^K \exp(y_c)} \quad (3.2.1)$$

したがって、分類器によって導かれる予測クラス C は、

$$C = \arg \max_{c \in Q} p_c \quad (3.2.2)$$

として求められる。また、モデル最終層以外の活性化関数については、全結合層の活性化関数には leaky ReLU を、畳み込み層の活性化関数には ReLU を用いた。最終層の全結合層の前には、ドロップアウト層があり、ドロップアウト率は 80%とした。その他の実験条件を表 3.1 に示す。教師ありデータ数 4,680 は、訓練データセット全てを用いた教師あり学習であることに注意されたい。

表 3.1 半教師あり学習の実験条件

教師ありデータ数	4, 8, 16, 32, 64, 128, 256, 512, 1,024, 2,048, 4,096, 4,680
Epoch	25 (10,000 iterations)
Batch size	16
Optimizer	Adam [23]($\lambda = 0.001, \beta = (\beta_1, \beta_2) = (0.9, 0.999)$)
ξ in VAT	0.00001
ε in VAT	8.0

分類モデルの損失関数について、教師ありデータに対する損失関数 $\mathcal{L}_{labeled}$ には交差エントロピー (cross entropy) を利用し、教師なしデータに対しては VAT および Entropy Minimization における損失関数を適用した。よって、モデル全体の目的関数 \mathcal{L} は、式 (3.1.3) および式 (3.1.14) を用いて、以下のように定義される。

$$\mathcal{L} = \mathcal{L}_{labeled} + \mathcal{L}_{vadv} + \mathcal{L}_{EntMin} \quad (3.2.3)$$

この目的関数を最小化することで、教師なしデータの予測ラベルの不確かさを減らしながら、教師ありデータの真の予測分布の学習を行い、かつ教師なしデータを用いて正則化を行うことができる。

分類の評価指標として、Precision (P), Recall (R), $F1$ を用いた。 $K = 4$ の多クラス分類であるため、評価の簡易化のために要約量としてマクロ平均を用いた。マクロ平均は、教師ラベルの各クラスごとに評価値を計算し、それらを平均したものである。各評価指標の定義式を以下に示す。

$$\text{Precision: } P = \frac{TP}{TP + FP} \quad (3.2.4)$$

$$\text{Recall: } R = \frac{TP}{TP + FN} \quad (3.2.5)$$

$$F1 = \frac{2PR}{P + R} \quad (3.2.6)$$

ここで、 TP 、 FP 、 FN および TN の定義表を表 3.2 に示す。

表 3.2 TP 、 FP 、 FN および TN の定義表


		Prediction	
		positive	negative
Truth	positive	TP	FN
	negative	FP	TN

すなわち、 TP は予測で positive とされたもののうち真に positive であるサンプルの数を表し、 FP は予測で positive とされたもののうち、本当は negative であるサンプルの数を示す。 FN は予測で negative とされたもののうち、本当は positive であるサンプルの数を表し、 TN は予測で negative とされたもののうち、真に negative であるサンプルの数である。


教師なしデータがどれほど分類性能に影響を及ぼすのかを調べるため、教師あり学習との比較も行なった。教師あり学習の場合は、学習するデータ数を半教師あり学習時と同様に 4~4,680 まで段階的に変化させた。その他の実験条件も半教師あり学習時と同様である。

3.3 結果・考察


図 3.1、図 3.2 に半教師あり学習における心電波形分類の混同行列を示す。また、図 3.3、図 3.4 に教師あり学習における心電波形分類の混同行列を示す。



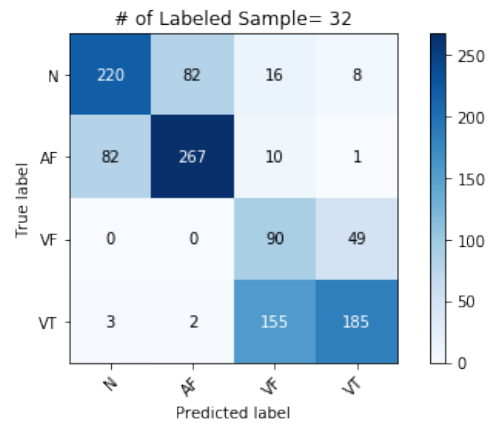
a. ラベルありのデータ数：4




b. ラベルありのデータ数：8




c. ラベルありのデータ数：16



d. ラベルありのデータ数：32




e. ラベルありのデータ数：64




f. ラベルありのデータ数：128


図 3.1 半教師あり学習における心電波形分類の混同行列 (1)




a. ラベルありのデータ数：256




b. ラベルありのデータ数：512




c. ラベルありのデータ数：1024



d. ラベルありのデータ数：2048

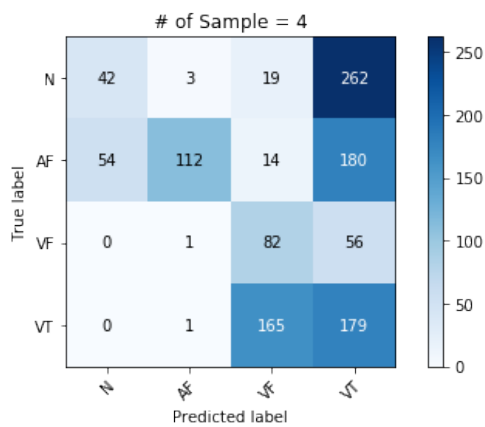


e. ラベルありのデータ数：4096




f. ラベルありのデータ数：4680


図 3.2 半教師あり学習における心電波形分類の混同行列 (2)




a. 学習データ数：4




b. 学習データ数：8




c. 学習データ数：16



d. 学習データ数：32




e. 学習データ数：64




f. 学習データ数：128


図 3.3 教師あり学習における心電波形分類の混同行列 (1)



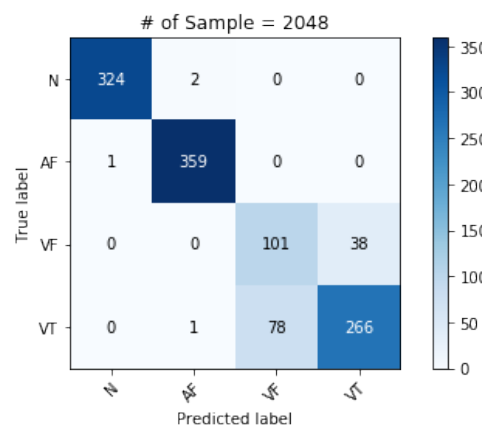
a. 学習データ数：256



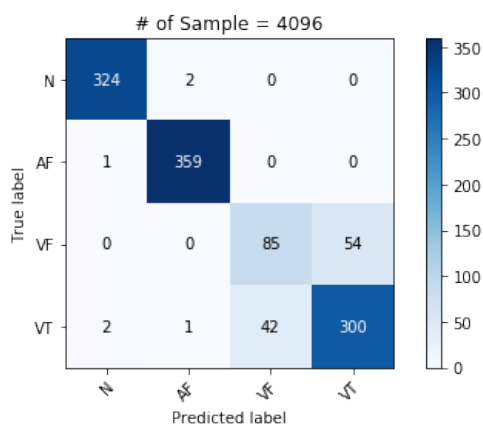
b. 学習データ数：512




c. 学習データ数：1024



d. 学習データ数：2048



e. 学習データ数：4096



f. 学習データ数：4680

図 3.4 教師あり学習における心電波形分類の混同行列 (2)

表 3.3 に半教師あり学習における分類性能の評価結果を示す。表 3.4 に教師あり学習における分類性能の評価結果を示す。図 3.5, 図 3.6, 図 3.7 にこれらのグラフを示す。グラフの縦軸は, 図 3.5 が Precision の値, 図 3.6 が Recall の値, 図 3.7 が F1 の値を示す。グラフの横軸は, 半教師あり学習についてはラベル付きデータの数を示し, 教師あり学習については訓練時のデータの数を示す。

表 3.3 半教師あり学習における分類性能の評価結果

ラベル付きデータ数	Precision	Recall	F1
4	0.392	0.397	0.313
8	0.497	0.496	0.494
16	0.585	0.581	0.572
32	0.644	0.650	0.629
64	0.638	0.627	0.615
128	0.736	0.733	0.732
256	0.806	0.812	0.807
512	0.827	0.813	0.817
1,024	0.835	0.801	0.806
2,048	0.864	0.861	0.862
4,096	0.834	0.801	0.806
4,680	0.878	0.798	0.800

表 3.4 教師あり学習における分類性能の評価結果

ラベル付きデータ数	Precision	Recall	F1
4	0.488	0.387	0.353
8	0.547	0.554	0.495
16	0.543	0.529	0.487
32	0.583	0.581	0.533
64	0.621	0.608	0.599
128	0.781	0.784	0.782
256	0.782	0.787	0.783
512	0.817	0.821	0.818
1,024	0.835	0.854	0.827
2,048	0.857	0.872	0.861
4,096	0.875	0.868	0.871
4,680	0.878	0.798	0.800




図 3.5 半教師あり学習および教師あり学習における Precision の値




図 3.6 半教師あり学習および教師あり学習における Recall の値

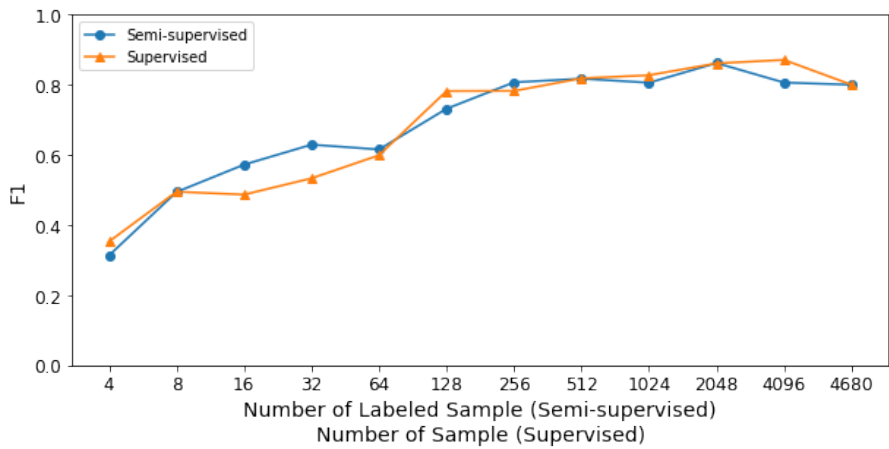


図 3.7 半教師あり学習および教師あり学習における F1 の値

図 3.1～図 3.4 の混同行列から分かるように、教師ありデータ数が少ないうちは、教師ラベルクラス N と AF との誤分類および VT と VF との誤分類が目立つ。これは、ラベル N と AF の心電波形の形状の類似性が高く、また、VT と VF の心電波形も極めて似通っているからであると考えられる。教師ありデータ数が 256 付近を超えると、N と AF の識別が極めて正確に行えるにも関わらず、VT と VF については教師ありデータの個数が 4,000 を超えても混同が見られることから、VT と VF の識別は困難を極めることが分かる。

一般的に Precision および Recall の値はトレードオフの関係にあるため、一方が高くなると他方は下がる傾向にあるが、図 3.3、図 3.4 から分かるように、本研究においては Precision および Recall はほぼ同様な値となった。Precision が低ければアノテーションの信頼性が下がり、Recall が低ければ疾患を見逃すという重大な過失につながるため、ラベル付きデータ数が増えるにつれて、これらの値が共に高くなる傾向にあるのは好ましい結果である。考察がしやすいように、以降では Precision と Recall との調和平均である F1 に焦点をあてる。

半教師あり学習の結果と教師あり学習の結果を比較すると、図 3.7 から、一部を除いてほぼ同等の性能が得られていることが分かる。一見すると、半教師あり学習時において、教師なしデータの恩恵がモデルに反映されていないように見える。しかし、図 3.7 の横軸の値（教師ありデータ数）が 16 および 32 であるとき、半教師ありモデルの性能が教師ありモデルの性能を大きく上回っていることが分かる。このことから、教師ありデータ数が 16～32 付近であるとき、教師ありデータから教師ラベルクラスの情報をもっと学習することができ、また教師なしデータによる正則化によって、少数の教師ありデータへの過学習を防ぐことができると考えられる。ただし、教師ありデータ数が 32 を超えると、教師ありデータから得られる情報の価値が、教師なしデータから得られる情報の価値を上回り、半教師ありモデル・教師ありモデルいずれのモデルにおいても分類性能に差がなくなると考えられる。

同等の分類性能であったとしても、各教師ラベルクラスに対する分類性能の向上の仕方に違いが見られた。図 3.1 および図 3.3 の混同行列をみると、教師ありモデルのほうが、ラベルクラス N・AF 間での混同を早く解消できていることが分かる。これは、半教師ありモデルにおいては、VAT による正則化が行われており、各ラベルクラス間での予測分布の重複領域が増大したためであると考えられる。このことから、VAT による正則化は、心電波形データに対しては強く働きすぎる可能性が示唆される。心電波形に対する最適な正則化方法についての議論は少ないため、この問題は、心電図解析研究において今後の重要な課題であるといえる。

半教師あり学習による心電図のアノテーション補助が、作業者に与える影響について考える。本研究で用いた心電図セグメントは、1 セグメントにつき 3 秒間の心電波形デ

ータである。成人の心拍数をおよそ 80bpm とすると 3 秒間での心拍数は、 $80[\text{bpm}] \div 60[\text{秒}] \times 3[\text{秒}] = 4[\text{beats}]$ となる。すなわち、1つの心電図セグメント内にはおよそ 4 拍動分の波形が含まれる。本研究で用いた MITDB のデータにおいては、ビートアノテーションも考慮して心電図セグメントのラベル付けを行なっている。同様なラベル付けを行う場合、1 拍動ずつの波形それぞれにアノテーションを行う必要がある。1 拍動分の波形のアノテーションにかかる時間をおよそ 1 秒とすると、1つの心電図セグメントのビートアノテーションにかかる時間は $4[\text{beats}] \times 1[\text{秒}] = 4[\text{秒}]$ となる。よって、ラベル付けをしたいデータの数 N とすると、これらのアノテーションにかかる時間は $4N$ 秒となる。従って、アノテーションの提示結果の確認作業にかかる時間を考慮しない場合は、アノテーション作業者の作業負担はおよそ $4N$ 秒だけ軽減されると考えられる。

3.4 半教師あり学習 まとめ

本研究では、VAT および Entropy Minimization を用いて、心電波形の自動分類における半教師あり学習手法の有効性を検証した。VAT および Entropy Minimization を用いることで、教師ありデータが少数（およそ 16~32 サンプル）である場合には半教師あり学習によって、通常の教師あり学習よりも精度の高い分類を行うことができた。よって、このようなラベル付きデータ数しか得られない場合は、半教師あり学習を用いることでより正確なアノテーション補助を行えることが示唆された。一方で、データ数が増えるにしたがって、教師なしデータを用いる効果が薄れることもわかった。これは VAT による正則化が心電波形データに適合しておらず、ノイズとして学習に強く影響を及ぼすためだと考えられる。より詳細な正則化手法の比較検証が必要であると考えられる。本研究では、半教師あり学習手法として VAT および Entropy Minimization を用いたが、画像分類研究の領域において、より性能の高い半教師あり学習手法が提案されている [24] [25] [26]。これらの手法が心電波形データにも有効か否かを検証するのは今後の課題の一つである。また、本研究では心電波形の信号データに対して、計算コストや学習の容易性から、畳み込みニューラルネットワーク (Convolutional neural network; CNN) をベースにしたネットワークにて分類を行なっているが、時系列データに通常用いられる LSTM (Long Short-Term Memory) [27] や GRU (Gated Recurrent Unit) [28] などの再帰型ニューラルネットワーク (Recurrent Neural Network; RNN) をベースとした分類モデルも検討する価値がある。また、Attention [29] ベースの分類モデルを使って心電波形の分類を行なった例 [30] もあり、このモデルは精度も高いため、半教師あり学習においても性能改善に役立つことが期待できる。本研究では入力データとして心電波形の信号データを用いたが、フーリエ変換やウェーブレット変換などの周波数分解手法で得られる周波数データを入力データとして加えるなど、データの前処理・加工への工夫も今後の課題となる。

第4章 Data Augmentation

本章では、生成モデルを利用した心電波形の Data Augmentation (データの水増し) について述べる。病例自体が珍しいあるいは検出の難しい心臓疾患に対する心電波形はデータそのものが少なく、心電波形の自動分類に必要な十分なデータ数が得られない場合がある。本研究においても、正常波形と比較して、心房細動 (AF) や心室性の疾患 (VT・VF) の心電波形データが少ないことが原因で、アンダーサンプリングによるデータ数の均等化を行なっている。一般に、機械学習による分類は、データ数が多いほど性能が高まる傾向があるため、データの水増しは重要な課題の一つである。通常、心電波形などの信号データに対して Data Augmentation を行う場合は、信号の時間軸をずらしたり、信号を分割する際に一部重複を許して分割するなどの手段が取られる。しかし、これらの手法は複数の水増しされたデータ内に、オリジナルデータと完全に同一なデータ部分が出現することになり、過学習の原因となる。また、画像データなどに用いられる、データの回転や色相変化などの Data Augmentation 手法は、一次元の信号データである心電波形にはそのまま適用することができないため、別のアプローチが必要となる。

本研究では、データ生成モデル手法の一つである Variational Autoencoder (VAE) [31] [32] を用いて心電波形データの生成を行った。さらにこの結果を元に、半教師あり学習における、生成モデルによる心電波形の Data Augmentation の利用可能性について議論した。本章の 4.1 節において、本実験で用いる Convolutional Autoencoder (CAE) および VAE の詳細を述べる。また、4.2 節において、CAE による心電波形再構築および、VAE による心電波形生成についてそれぞれ述べる。

4.1 手法

VAE による心電波形生成の実験を行う前に、VAE 内で用いる Convolutional Autoencoder (CAE) のネットワーク構造を先行研究 [33] を元に模索する。その後、心電波形の再構築が可能なネットワーク構造を応用し、VAE による心電波形の生成実験を行う。以下で Autoencoder および CAE, VAE の詳細について述べる。

4.1.1 Autoencoder

Autoencoder (AE) [34] は、ニューラルネットワークを用いた次元削減手法の一つである。次元削減手法の目的の一つは、データを表す高次元特徴ベクトルを、そのデータを表現するのに必要な最小の低次元特徴ベクトルへと変換することである。次元削減手法には AE の他に、主成分分析 (Principal Component Analysis; PCA) や独立成分分析 (Independent Component Analysis; ICA) などがある。AE を用いる利点は、ニューラルネットワーク構造による表現力の高さにある。すなわち、画像や信号データなどの高次元特徴ベクトルに対しても、高い精度で適切な低次元特徴ベクトルへと変換することが

できると考えられる。以下では、AEの詳細について述べる。

最も単純なAEのネットワーク構造を図4.1に示す。図4.1中の \mathbf{x} は入力である高次元特徴ベクトルを示し、 \mathbf{z} は低次元特徴ベクトル、 $\tilde{\mathbf{x}}$ は \mathbf{x} と同数の次元数をもつベクトルである。また、 \mathbf{W}_e および \mathbf{W}_d はネットワークの重みパラメータ、 \mathbf{b}_e および \mathbf{b}_d はバイアスである。AEでは、入力 \mathbf{x} から低次元ベクトル \mathbf{z} へ、 \mathbf{z} から高次元ベクトル $\tilde{\mathbf{x}}$ へと変換が行われるが、この際に \mathbf{x} と $\tilde{\mathbf{x}}$ とが同一になるように \mathbf{W}_e 、 \mathbf{W}_d 、 \mathbf{b}_e 、 \mathbf{b}_d の最適化を行う。 \mathbf{x} と $\tilde{\mathbf{x}}$ とが限りなく等しい場合、 \mathbf{z} は元の高次元特徴ベクトル \mathbf{x} を、より低い次元数で表現できていると考えられる。 \mathbf{z} は一般に、潜在変数と呼ばれ、入力 \mathbf{x} から潜在変数 \mathbf{z} への変換を行う機構をエンコーダ (Encoder)、潜在変数 \mathbf{z} から出力 $\tilde{\mathbf{x}}$ へと変換する機構をデコーダ (Decoder) と呼ぶ。




図 4.1 Autoencoder のネットワーク構造

潜在変数 \mathbf{z} は、活性化関数 f を用いると、

$$\mathbf{z} = f(\mathbf{W}_e \mathbf{x} + \mathbf{b}_e) \quad (4.1.1)$$

と表すことができる。また、 $\tilde{\mathbf{x}}$ への再構築は f' を活性化関数とすると、

$$\tilde{\mathbf{x}} = f'(\mathbf{W}_d \mathbf{z} + \mathbf{b}_d) \quad (4.1.2)$$

となる。 $\mathbf{x} = (x_1, x_2, \dots, x_N)$ と $\tilde{\mathbf{x}} = (\tilde{x}_1, \tilde{x}_2, \dots, \tilde{x}_N)$ とが同一になるように学習を行うが、この際の損失関数 \mathcal{L}_{AE} は式(4.1.3)に示すように、平均最小二乗誤差 (Mean Squared Error; MSE) を用いる。

$$\mathcal{L}_{AE} = \frac{1}{N} \sum_{i=1}^N \|x_i - \tilde{x}_i\|^2 \quad (4.1.3)$$

AEの各特徴ベクトル間のネットワーク構造を多層にしたり，畳み込みニューラルネットワークを用いることも可能である．畳み込みニューラルネットワークを用いたものをConvolutional Autoencoder (CAE) と呼び，CAE ベースの次元削減手法を用いた心電波形の再構成はすでに先行研究の論文内 [33] において，実現可能であることが示されている．よって本研究では，先行研究で用いられた CAE 構造を改良し，本研究で用いるデータセットにおいても波形の再構築ができるよう実験を行った．

4.1.2 Variational Autoencoder

Variational Autoencoder (VAE) [31] [32] は通常の Autoencoder の潜在変数 \mathbf{z} に任意の確率分布(通常は正規分布 $\mathcal{N}(0, 1)$)を仮定し，学習を行う手法である．通常の Autoencoder においては， \mathbf{z} に任意の確率分布が仮定されているわけではないため，その構造がどのようなものかが不明である．それに対し，VAE は \mathbf{z} に確率分布が仮定されているため，モデルの学習後に，その確率分布からサンプリングされる任意のベクトルをデコーダへと入力することで，新規のデータを生成することが可能である．サンプリングからデータ生成までを行う機構をジェネレータ (generator) と呼ぶ．図 4.2 に VAE の概要図を示す．VAE では，ニューラルネットワークによる学習を可能にするために，後に述べる reparameterization trick という手法を用いており， $\boldsymbol{\varepsilon} \sim \mathcal{N}(0, I)$ (I は単位行列) を介することで \mathbf{z} を求めている．




図 4.2 VAE の概要図

VAE において重要な概念である，変分下限について述べる．エンコーダのパラメータを $\boldsymbol{\phi}$ とし，ジェネレータのパラメータを $\boldsymbol{\theta}$ とする．エンコーダの出力の確率分布を $q_{\boldsymbol{\phi}}(\mathbf{z}|\mathbf{x})$ ，ジェネレータの出力の確率分布を $p_{\boldsymbol{\theta}}(\mathbf{x}|\mathbf{z})$ とする．また，データ集合を $\mathbf{X} = \{x^{(i)}\}_{i=1}^N$ (N は整数) とすると，周辺尤度 $\log p_{\boldsymbol{\theta}}(\mathbf{x}^{(1)}, \dots, \mathbf{x}^{(N)})$ は，各データの周辺尤度の

総和で表せる。

$$\log p_{\theta}(\mathbf{x}^{(1)}, \dots, \mathbf{x}^{(N)}) = \sum_{i=1}^N \log p_{\theta}(\mathbf{x}^{(i)}) \quad (4.1.4)$$

各データの周辺尤度を直接求めるのは困難であるため、以下で説明する変分下限 (variational lower bound) と呼ばれる値を導入し、これを最大化することによって周辺尤度の最大化を行うことを考える [35]。変分下限を $\mathcal{L}(\boldsymbol{\theta}, \boldsymbol{\phi}; \mathbf{x}^{(i)})$ とすると、各データの周辺尤度と $\mathcal{L}(\boldsymbol{\theta}, \boldsymbol{\phi}; \mathbf{x}^{(i)})$ との関係は、イェンセンの不等式を用いて、

$$\begin{aligned} \log p_{\theta}(\mathbf{x}^{(i)}) &= \log \int p_{\theta}(\mathbf{x}^{(i)}, \mathbf{z}) d\mathbf{z} \\ &= \log \int q_{\phi}(\mathbf{z}|\mathbf{x}^{(i)}) \frac{p_{\theta}(\mathbf{x}^{(i)}, \mathbf{z})}{q_{\phi}(\mathbf{z}|\mathbf{x}^{(i)})} d\mathbf{z} \\ &\geq \int q_{\phi}(\mathbf{z}|\mathbf{x}^{(i)}) \log \frac{p_{\theta}(\mathbf{x}^{(i)}, \mathbf{z})}{q_{\phi}(\mathbf{z}|\mathbf{x}^{(i)})} d\mathbf{z} \\ &= \mathcal{L}(\boldsymbol{\theta}, \boldsymbol{\phi}; \mathbf{x}^{(i)}) \\ \therefore \log p_{\theta}(\mathbf{x}^{(i)}) &\geq \mathcal{L}(\boldsymbol{\theta}, \boldsymbol{\phi}; \mathbf{x}^{(i)}) \end{aligned} \quad (4.1.5)$$

と表すことができる。このとき、周辺尤度と変分下限の差分を計算すると、

$$\log p_{\theta}(\mathbf{x}^{(i)}) - \mathcal{L}(\boldsymbol{\theta}, \boldsymbol{\phi}; \mathbf{x}^{(i)}) = D_{KL}[q_{\phi}(\mathbf{z}|\mathbf{x}^{(i)})||p_{\theta}(\mathbf{z}|\mathbf{x}^{(i)})] \quad (4.1.6)$$

となる。ただし、 $D_{KL}[p||p']$ は確率変数 p および p' の KL-divergence を表す。式 (4.1.6) より、各データの周辺尤度は以下のようなになる。

$$\log p_{\theta}(\mathbf{x}^{(i)}) = D_{KL}[q_{\phi}(\mathbf{z}|\mathbf{x}^{(i)})||p_{\theta}(\mathbf{z}|\mathbf{x}^{(i)})] + \mathcal{L}(\boldsymbol{\theta}, \boldsymbol{\phi}; \mathbf{x}^{(i)}) \quad (4.1.7)$$

また、変分下限は、

$$\mathcal{L}(\boldsymbol{\theta}, \boldsymbol{\phi}; \mathbf{x}^{(i)}) = \log p_{\theta}(\mathbf{x}^{(i)}) - D_{KL}[q_{\phi}(\mathbf{z}|\mathbf{x}^{(i)})||p_{\theta}(\mathbf{z}|\mathbf{x}^{(i)})] \quad (4.1.8)$$

と表せる。この式の右辺第二項の KL-divergence を計算すると、式 (4.1.8) は最終的に以下のようなになる。

$$\mathcal{L}(\boldsymbol{\theta}, \boldsymbol{\phi}; \mathbf{x}^{(i)}) = -D_{KL}[q_{\boldsymbol{\phi}}(\mathbf{z}|\mathbf{x}^{(i)})||p_{\boldsymbol{\theta}}(\mathbf{z})] + \mathbb{E}_{q_{\boldsymbol{\phi}}(\mathbf{z}|\mathbf{x}^{(i)})}[\log p_{\boldsymbol{\theta}}(\mathbf{x}^{(i)}|\mathbf{z})] \quad (4.1.9)$$

VAE ではこの変分下限 $\mathcal{L}(\boldsymbol{\theta}, \boldsymbol{\phi}; \mathbf{x}^{(i)})$ を最大化することで、周辺尤度の最大化を行う。式 (4.1.9) より変分下限の最大化は、右辺第一項の KD-divergence の最小化および第二項の、 $q_{\boldsymbol{\phi}}(\mathbf{z}|\mathbf{x}^{(i)})$ の下における $p_{\boldsymbol{\theta}}(\mathbf{x}^{(i)}|\mathbf{z})$ の対数尤度の期待値最大化と等価である。右辺第一項の KD-divergence について、論文 [31] APPENDIX B において、 $q_{\boldsymbol{\phi}}(\mathbf{z}|\mathbf{x}^{(i)})$ が平均 $\boldsymbol{\mu} = \{\mu_1, \dots, \mu_J\}$ 、分散 $\boldsymbol{\sigma}^2 = \{\sigma_1^2, \dots, \sigma_J^2\}$ の正規分布 $\mathcal{N}(\boldsymbol{\mu}, \boldsymbol{\sigma}^2)$ に従う場合の KL-divergence が計算されており、 \mathbf{z} の次元数を J とすると、その KL-divergence は、

$$D_{KL}[q_{\boldsymbol{\phi}}(\mathbf{z}|\mathbf{x}^{(i)})||p_{\boldsymbol{\theta}}(\mathbf{z})] = -\frac{1}{2} \sum_{j=1}^J \left(1 + \log \left((\sigma_j)^2 \right) - (\mu_j)^2 - (\sigma_j)^2 \right) \quad (4.1.10)$$

となる。本研究においても正規分布を仮定するため、この式を用いる。次に、式 (4.1.9) の右辺第二項について述べる。VAE の入力 \mathbf{x} から、エンコーダによって推定される確率分布 $q_{\boldsymbol{\phi}}(\mathbf{z}|\mathbf{x})$ に従う潜在変数 $\mathbf{z} \sim q_{\boldsymbol{\phi}}(\mathbf{z}|\mathbf{x})$ が得られる。また、出力 $\tilde{\mathbf{x}}$ はジェネレータに $\mathbf{z} \sim q_{\boldsymbol{\phi}}(\mathbf{z}|\mathbf{x})$ を入力することで得られる。このとき、ジェネレータの出力の確率分布は $p_{\boldsymbol{\theta}}(\mathbf{x}|\mathbf{z})$ に従う。式 (4.1.9) の右辺第二項における対数尤度の期待値最大化は、確率分布 $q_{\boldsymbol{\phi}}(\mathbf{z}|\mathbf{x})$ の下での $p_{\boldsymbol{\theta}}(\mathbf{x}^{(i)}|\mathbf{z})$ の尤度の期待値最大化を意味する。そのため、これらの確率分布を通して得られる VAE の出力 $\tilde{\mathbf{x}}$ について、入力 \mathbf{x} との交差エントロピーなどを損失とし最小化することで、期待値最大化を達成することができる。入力 \mathbf{x} と出力 $\tilde{\mathbf{x}}$ との交差エントロピーによる損失を簡略化のために \mathcal{L}_{CE} とすると、学習の際に最小化する目的関数 \mathcal{L}' は、式 (4.1.9), (4.1.10) より、

$$\begin{aligned} \mathcal{L}' &= D_{KL}[q_{\boldsymbol{\phi}}(\mathbf{z}|\mathbf{x}^{(i)})||p_{\boldsymbol{\theta}}(\mathbf{z})] + \mathcal{L}_{CE} \\ &= -\frac{1}{2} \sum_{j=1}^J \left(1 + \log \left((\sigma_j)^2 \right) - (\mu_j)^2 - (\sigma_j)^2 \right) + \mathcal{L}_{CE} \end{aligned} \quad (4.1.11)$$

と表せる。この目的関数の最小化によって、変分下限の最大化を実現できる。ただし、潜在変数 \mathbf{z} は確率分布 $q_{\boldsymbol{\phi}}(\mathbf{z}|\mathbf{x}) = \mathcal{N}(\boldsymbol{\mu}, \boldsymbol{\sigma}^2)$ からサンプリングされるため、モデルとしてニューラルネットワークを用いる場合に、逆伝搬誤差を計算することが困難である。この問題を解決するため、reparameterization trick を用いて \mathbf{z} を求める。ランダムノイズ $\boldsymbol{\varepsilon} \sim \mathcal{N}(0, I)$ および、図 4.2 に示すように入力 \mathbf{x} から求めた平均 $\boldsymbol{\mu}$ 、分散 $\boldsymbol{\sigma}^2$ を用いて、 \mathbf{z} を以下のように求める。

$$z = \mu + \sigma^2 \odot \varepsilon \quad (4.1.12)$$

ここで、 \odot は2つのベクトルの要素同士の掛け算（要素積）を表す。これにより、ネットワーク学習時に逆伝搬を行うことが可能となる。

本研究では、VAEの生成モデルとしての機能を利用し、新規の心電図セグメントを生成する試みを行なった。これにより、半教師あり学習および教師なし学習において、教師ラベル数の少ないデータの水増し、およびそれに伴う性能向上が期待できる。

4.2 実験

本研究で行なった、CAEによる心電波形の再構築実験および、VAEによる心電波形の生成実験について述べる。

4.2.1 Convolutional Autoencoder による心電波形の再構築

まず、CAEによる心電波形再構築の実験について述べる。

4.2.1.1 実験方法

先行研究 [33] をもとに CAE による心電波形再構築を行った。本研究で用いた CAE のネットワーク構造を図 4.3 に示す。図 4.3 中の Conv1~Conv5 および Deconv1~Deconv6 は、それぞれ Convolution 層と Deconvolution 層を示している。これらの畳み込み層の詳細構造を表 4.1 に示す。各層の活性化関数として ELU 関数を用いた。ただし、最終層 (Deconv6) には活性化関数を用いていない。その他の実験条件を表 4.2 に示す。このモデルに、2章で述べたデータセットに対して正規化 ([0, 1]で Min-Max Scaling) を行なったものを入力し、波形が再構築できるか検証した。

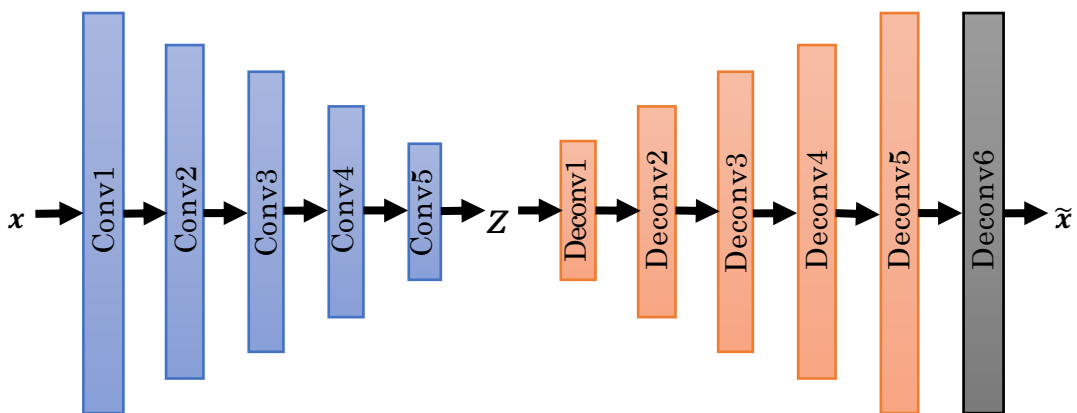


図 4.3 実験で用いた CAE のネットワーク構造

表 4.1 CAE の畳み込み層の詳細構造

畳み込み層	Filter 数	Filter Size	Stride
Conv1	40	16	2
Conv2	20	16	2
Conv3	20	17	2
Conv4	40	17	2
Conv5	1	16	1
Deconv1	1	16	1
Deconv2	40	17	2
Deconv3	20	17	2
Deconv4	20	16	2
Deconv5	40	16	2
Deconv6	1	16	1

表 4.2 CAE による心電波形再構築の実験条件

\mathbf{z} の次元数	33
Epoch	2,048
Batch size	32
Optimizer	Adam ($\lambda = 0.0002, \beta = 0.5$)
Loss	RMSE (Root Mean Squared Error)

4.2.1.2 心電波形の再構築結果・考察

図 4.4～図 4.7 に CAE による心電波形の再構築結果の例をしめす。各図の左列が入力波形を示し、右列が再構築された波形を示す。最終的な再構築の損失の値は、データ全体では 0.0754 であった。また、クラス (N, AF, VT, VF) ごとの損失は、それぞれ、N が 0.0635, AF が 0.0592, VT が 0.0875, VF が 0.0978 であった。クラスごとの損失の値を比べると、N および AF に比べて VT, VF の損失の方が高い。これは、VT, VF の波形が N および AF に比べて 3 秒間に振動する回数が多いため、それぞれの振幅などを正確に再現するのが難しいためであると考えられる。特に、VF は周期性に欠け、データ数も少ないため学習が進みにくく、損失の値が比較的高くなったと考えられる。損失の値は多少高いものの、図 4.4～図 4.7 に示すようにいずれのクラスの波形も、ある程度再現できていることが分かる。よって本研究では、この CAE モデル構造を心電波形再構築用のモデルとして採用し、VAE による波形生成へと応用することにした。




図 4.4 CAE による心電波形再構築の結果の例 (クラス : N)




図 4.5 CAE による心電波形再構築の結果の例 (クラス : AF)




図 4.6 CAE による心電波形再構築の結果の例 (クラス: VT)




図 4.7 CAE による心電波形再構築の結果の例 (クラス: VF)

4.2.2 Variational Autoencoder による心電波形生成

VAE による心電波形の再構築および生成について述べる。また、生成された心電波形が、水増しデータとして不整脈自動分類へと利用が可能かを議論する。

4.2.2.1 実験方法

前節 4.2.1 の実験で得られた CAE (以降, 心電波形用 CAE とよぶ) をベースに VAE モデルを構築する。図 4.8 に実験で用いた VAE のネットワーク構造を示す。FC1~FC3 は, 全結合層を表す。各畳み込み層の詳細構造を表 4.3 に示す。畳み込み層および FC3 の活性化関数として, ReLU 関数を用いた。ただし, 最終層である Deconv5 には, 正則化のために Sigmoid 関数を用いた。また, FC1 および FC2 に活性化関数はない。VAE によって波形を生成する場合は, 正規分布 $\mathcal{N}(0, 1)$ からサンプリングされた \mathbf{z} を用いる。その他の実験条件を表 4.4 に示す。これらの条件下で, VAE による波形の再構築および生成を行い, Data Augmentation の手段として用いることができるかを考察した。

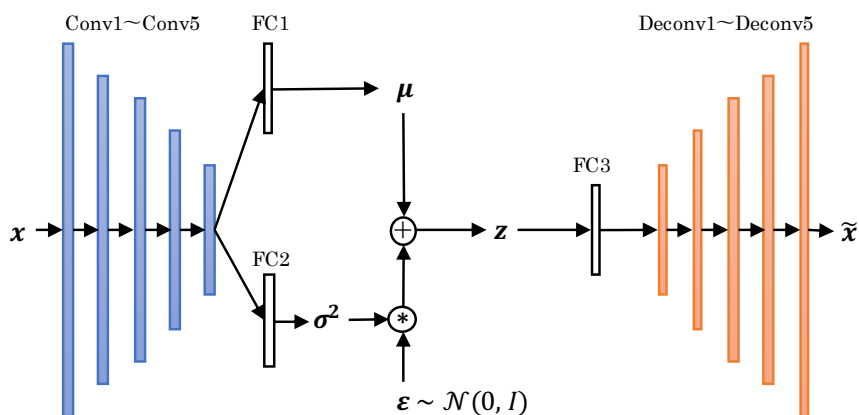


図 4.8 実験で用いた VAE のネットワーク構造

表 4.3 VAE の畳み込み層の詳細構造

畳み込み層	Filter 数	Filter Size	Stride
Conv1	40	16	2
Conv2	20	16	2
Conv3	20	16	2
Conv4	20	16	2
Conv5	40	16	2
Deconv1	20	15	2
Deconv2	20	16	2
Deconv3	20	16	2
Deconv4	40	15	2
Deconv5	1	16	2

表 4.4 VAE による心電波形再構築・生成の実験条件

\mathbf{z} の次元数	24
Epoch	2,000
Batch size	16
Optimizer	Adam ($\lambda = 0.001, \beta = (0.9, 0.999)$)

4.2.2.2 結果

VAE による心電波形の再構築結果および生成結果を示し、考察を行う。

4.2.2.2.1 VAE による心電波形の再構築結果・考察

図 4.9～図 4.12 に VAE による心電波形の再構築結果の例をしめす。図 4.11, 図 4.12 から、VT, VF は問題なく再構築できていることが分かる。しかし、N および AF, 特に N における再構築がうまくいかず、波形が歪んでいるものが多く散見された。心電波形用 CAE では、N および AF の再構築ができていたことを考慮すると、VAE にて N, AF の再構築がうまくいかない理由として、正規分布への埋め込みによって、N, AF の特徴が歪み、再構築に必要な情報が失われてしまっていることが考えられる。N に対する再構築では、VT, VF の波形へと引きずられてしまっているものも複数存在している。これらは、学習の際に各データのクラス情報を訓練するようなモデルを用いることで解決できると思われる。すでに、VAE にクラス情報を含めて学習を行う手法である Conditional VAE [32] が提案されている。VAE 以外の生成モデルにおいても同様にクラス情報を含める手法が考案されているため、これらを用いた場合に再構築がうまくできるかを検討するのが今後の課題の一つである。




図 4.9 VAE による心電波形再構築の結果の例 (クラス : N)

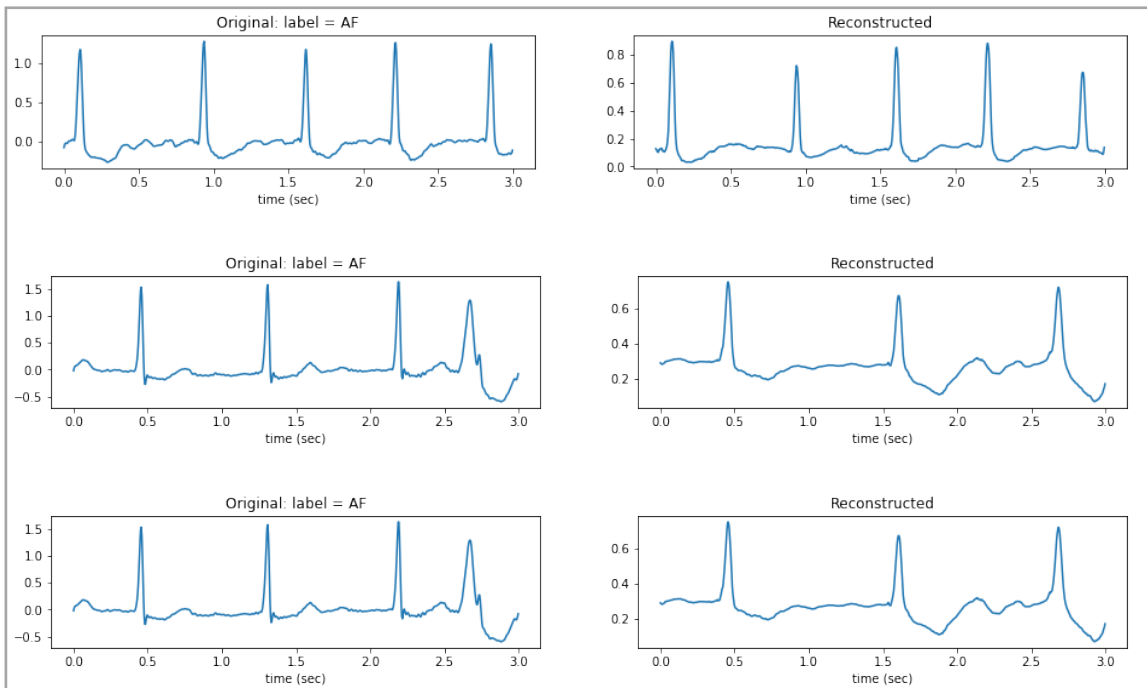


図 4.10 VAE による心電波形再構築の結果の例 (クラス : AF)

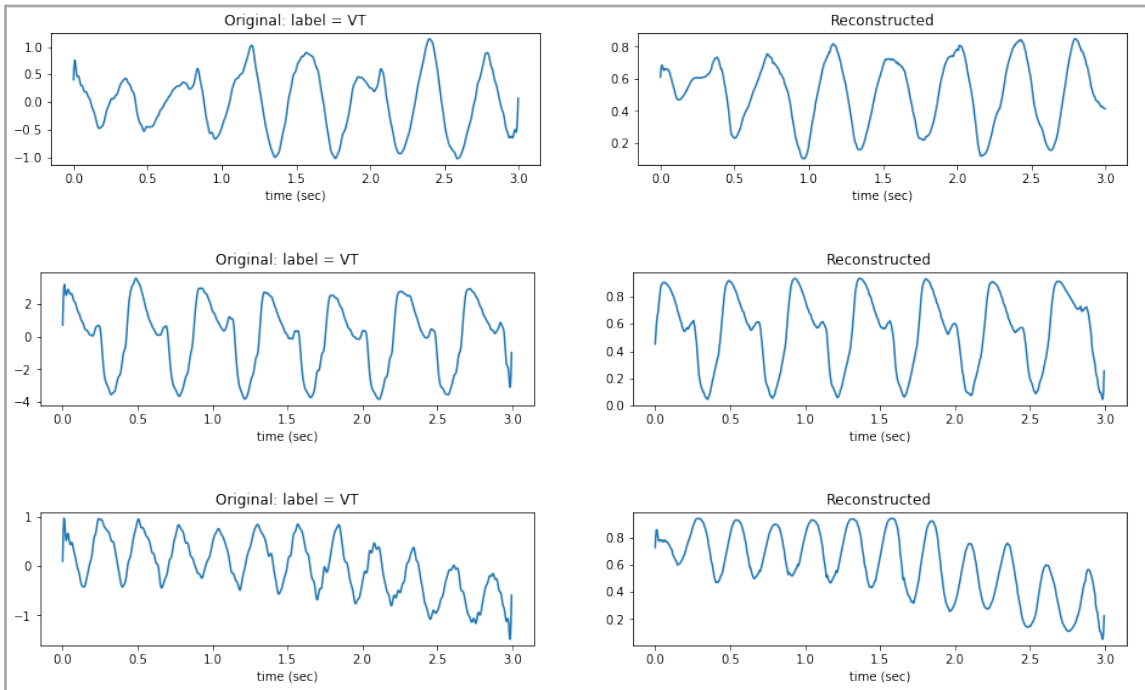


図 4.11 VAE による心電波形再構築の結果の例 (クラス : VT)

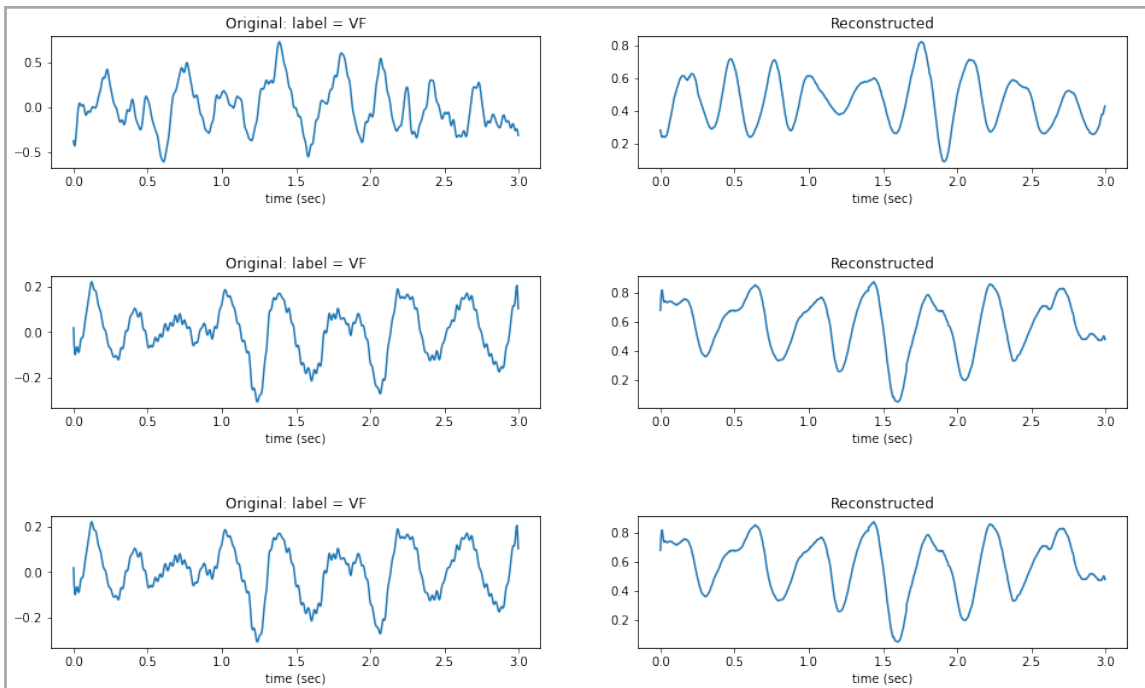


図 4.12 VAE による心電波形再構築の結果の例 (クラス : VF)

4.2.2.2.2 VAEによる心電波形の生成結果・考察

図 4.13 に VAE による心電波形の生成結果の例を示す。図 4.13 から分かるように、いくつかの生成波形は VT, VF の波形に非常に似ている。しかし、AF の波形だと思われるものは少なく、波形の一部に歪みが生じてしまっているものもあった。さらに、ラベルクラスが N であるといえる生成波形は極めて少なく、3 秒間の周期的な正常波形を生成するのは困難であることが示唆された。半教師あり学習に対する Data Augmentation として、本手法を活用する場合、比較的データ数の多い N の波形は水増しされなくてもよいため、N の生成の困難さはあまり問題にはならないと思われる。ただし、AF の波形の歪みや、いくつかの歪んだ VF, VT 波形は、波形からクラスを推定することが難しく、識別を阻害する大きなノイズになり得る。よって、本研究の提案手法において生成される心電波形をそのまま半教師あり学習の Data Augmentation に用いることは難しいと考えられる。

一方で、VT, VF の波形は再現性の高いものもあり、かつ AF の波形も一部の歪みは VT, VF の波形に引きずられたものであると思われるため、心電波形の再構築同様、学習時にクラス情報を含むようにすることで、より正確な波形が得られることが期待できる。

また、VAE において、特定のラベルクラスを指定してデータを生成するためには、潜在変数 \mathbf{z} の正規確率分布上における、各クラスのデータ中心点を探索する必要がある。それに対し、Conditional VAE などのクラス情報を含む学習手法では、データ生成時に、生成するデータのクラスを指定できる。従って、これらの手法では、教師ラベルがデータ生成時に水増しデータへと即時付与されるため、半教師あり学習や教師なし学習だけでなく、教師あり学習に対する Data Augmentation にも容易に活用できるという利点がある。




図 4.13 VAE による心電波形生成の結果の例

4.3 Data Augmentation まとめ

本研究では, VAE という生成モデルを利用し, 心電波形の生成を行なった. また, それらの生成データを水増しデータとして, 半教師あり学習へと活用できるか否かについて議論を行なった. 結果として, VAE によって生成された波形は, データの歪みが大きく, 水増しデータとしての活用は難しいことが示唆された. 一方で, 教師ラベルクラスによっては, いくつかの自然な心電波形が生成できた. また, 生成された心電波形の中には, 複数のクラスに属する部分波形が混在しているものも見受けられた. 従って, モデルの訓練時にクラス情報を含むような生成モデル手法を用いることで, より正確な心電波形の生成を行えることが期待できる. さらに, VAE ベースの生成モデルだけでなく Generative Adversarial Networks (GAN) [36] ベースの手法や Flow ベースの手法 [37] [38], あるいは VAE と GANs の組み合わせ手法である VAEGAN [39] などの他のデータ生成手法の活用も今後検討すべき事項である. 音声データと心電波形データは, 時系列の波形信号データとして共通項をもつと考えられるため, 音声データの生成モデルとして近年成功した WaveNet [40] なども応用できる可能性がある. 今後, 心電波形生成手法が発展し, Data Augmentation へと活用できるようになることを期待する.

第5章 教師なしクラスタリング

本研究は、アノテーション支援・診断支援を目的としている。心電波形に対する有用な知見を創出することは、不整脈自動分類手法へと与える情報を拡張することにつながり、精度向上に寄与すると考えられる。機械学習においては、新たな知見創出の手段として教師なしクラスタリングが広く用いられる。これらのクラスタリング手法は、新たな知見の創出だけでなく、アノテーション支援・診断支援にも直接応用することができると考えられる。本章では、教師なし学習を用いた心電波形のクラスタリングについて述べる。

5.1 手法

本研究では、教師なしクラスタリング手法の一つである Information Maximizing Self-Augmented Training (IMSAT) [41] を用いて、心電波形のクラスタリングを行なった。以下で IMSAT の詳細を述べる。

5.1.1 Information Maximizing Self-Augmented Training (IMSAT)

IMSAT は、手書き文字データセット MNIST の画像分類において、教師なし学習としては極めて高い精度での分類に成功した手法である。IMSAT は主に二つの手法の思想に基づく。一つは Regularized Information Maximization (RIM) [42] と呼ばれるもので、もう一つは Self-Augmented Training (SAT) と呼ばれるものである。IMSAT において、RIM は入力データと教師ラベルクラスの関係性を結びつける役割を果たす。一方で、SAT は RIM 内で用いる正則化手法である。これら二つの手法の組み合わせにより、IMSAT は頑健性の高いクラスタリングを教師ラベルなしで行うことが可能である。RIM と SAT の概要を以下で述べる。

5.1.2 Regularized Information Maximization (RIM)

RIM は、入力データ x が与えられたときのクラスドメイン y の予測確率分布 $p_{\theta}(y|x)$ について、入力データとクラスドメインの相互情報量 $I(X; Y)$ が最大になるように学習を行う手法である。RIM の目的関数 δ_{RIM} は以下のように表される。

$$\delta_{RIM} = \mathcal{R}(\theta) - \lambda I(X; Y) \quad (5.1.1)$$

ここで、 $\mathcal{R}(\theta)$ は RIM の正則化項であり、 λ はハイパーパラメータである。相互情報量 $I(X; Y)$ は、情報エントロピー $H(\cdot)$ 、 $h(\cdot)$ および conditional entropy $H(\cdot|\cdot)$ を用いると以下のように表される。

$$\begin{aligned}
I(X; Y) &= H(Y) - H(Y|X) \\
&= h\left(\frac{1}{N} \sum_{i=1}^N p_{\theta}(y|x_i)\right) - \frac{1}{N} \sum_{i=1}^N h(p_{\theta}(y|x_i))
\end{aligned} \tag{5.1.2}$$

相互情報量 $I(X; Y)$ は、入力 X とクラスドメイン Y の双方の情報依存度（ X についての情報が与えられた時に得られる Y についての情報、あるいは Y についての情報が与えられた時に得られる X についての情報）を表す。そのため、相互情報量を最大化することで、入力 X とクラスドメイン Y の依存構造を表現したクラスタリングが行われることになる。式(5.1.1)で既に示したように、RIMではこの相互情報量に正則化項を加えることで、頑健性を考慮したクラスタリングを行う。IMSATではRIMの正則化項として、self-augmented training (SAT) で得られる $\mathcal{R}_{SAT}(\theta)$ を用いる。

5.1.3 Self-Augmented Training (SAT)

IMSATで用いられるSATについて述べる。SATは学習に使用するデータセット自体を用いてデータを増強し、モデルの頑健性を高める手法である。モデルの訓練に用いるデータ数が少ない場合は、ノイズに弱いモデルとなることが知られている。そのため、あらかじめ入力データに微細なノイズを加える等の処理をおこなうことで、データ変形によるデータの水増しが行われる。IMSATにおいても、このデータ水増しを行うことで、頑健性の強化を行う。

データ x ($x \in \mathcal{D}$)に対する変形関数を $T(\cdot)$ 、確率距離 KL-divergence を $D_{KL}[p||p']$ とすると、IMSATで用いる正則化項 $\mathcal{R}_{SAT}(\theta; x, T(x))$ は以下のように表される。

$$\mathcal{R}_{SAT}(\theta; x, T(x)) = \frac{1}{N} \sum_{x \in \mathcal{D}} D_{KL}[p(y|x, \theta) || p(y|T(x), \theta)] \tag{5.1.3}$$

正則化項 $\mathcal{R}_{SAT}(\theta; x, T(x))$ を最小化することによって、オリジナルのデータ x に対する予測分布 $p(y|x, \theta)$ とノイズ付きデータに対する予測分布 $p(y|T(x), \theta)$ の確率分布が近づき、ノイズに対する頑健性が高まる。本研究では、変形関数 $T(\cdot)$ として、第3章3.1.1節で述べたVATを用いた。

5.2 実験方法

IMSATを用いて心電波形データの教師なしクラスタリングを行う。この際に、第2章において述べたデータセットの心電波形信号データを、画像データへと変換してからクラスタリングを行なった。これは、IMSATが画像分類タスクで高精度を発揮したこと、および医師の心電図診断も目視による診断であること、さらに先行研究 [43] において

も画像データを用いた場合のほうが分類精度が高いことが報告されていたためである。画像への変換は、python ライブラリの一つである matplotlib を用いた。画像サイズは 256×256 で保存し、モデルの訓練前に機械学習フレームワークである Tensorflow で実装されている関数を用いることで、最終的に 224×224 の心電波形画像へと変換した。モデルの分類器としては、Deep Residual Network (ResNet50) を用いた。ResNet50 の最終2層は全結合層とした。今回用いた ResNet50 は、最終2層の全結合層を除いて、ImageNet データセットによる事前学習が行われている。この分類器を用いて、クラスタリングのクラスター数 K (最終層の全結合層の次元数) を 2~10 へと変化させながら、クラスタリングを行なった。IMSAT 内で用いる VAT において、生成される摂動の更新回数は 1 とした。その他の実験条件を表 5.1 に示す。

表 5.1 教師なしクラスタリングの実験条件

クラスター数 K	2, 3, 4, 5, 6, 7, 8, 9, 10
Epoch	20
Batch size	16
Optimizer	Adam ($\lambda = 0.0002, \beta = 0.5$)
ξ in VAT	10
ε in VAT	0.25
λ	0.1

5.3 結果・考察

図 5.1~図 5.9 に IMSAT による心電波形画像のクラスタリングの結果を示す。これらの図は、IMSAT によって得られるクラスターごとの、教師ラベルクラスの構成比を表す。例えば、図 5.1 ではクラスター0 とクラスター1 の二つのクラスターがあり、クラスター1 の構成は N ラベルをもつ心電波形画像 (図内のオレンジ色) が約 5 割と、AF ラベルをもつ心電波形画像 (図内の青色) が約 5 割であることがわかる。




図 5.1 IMSAT による心電波形画像のクラスタリング結果 (K=2)




図 5.2 IMSAT による心電波形画像のクラスタリング結果 (K=3)




図 5.3 IMSAT による心電波形画像のクラスタリング結果 (K=4)

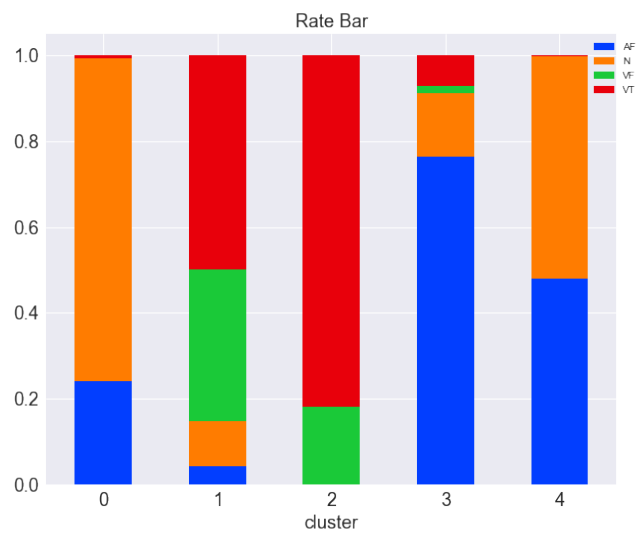


図 5.4 IMSAT による心電波形画像のクラスタリング結果 (K=5)

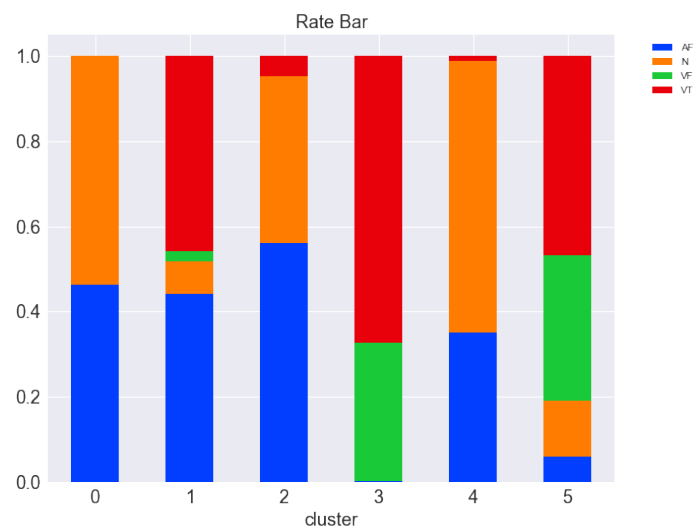


図 5.5 IMSAT による心電波形画像のクラスタリング結果 (K=6)




図 5.6 IMSAT による心電波形画像のクラスタリング結果 (K=7)




図 5.7 IMSAT による心電波形画像のクラスタリング結果 (K=8)




図 5.8 IMSAT による心電波形画像のクラスタリング結果 (K=9)




図 5.9 IMSAT による心電波形画像のクラスタリング結果 (K=10)

K=2 のクラスタリング結果 (図 5.1) において, クラスタ0 は VT・VF クラス, クラスタ1 は N・AF クラスのクラスタであることが分かる. VT と VF の心電波形が極めて似ていること, また N および AF の心電波形も極めて似ていることを考慮すると, それぞれが同じクラスタに分類されるのは自然であると言える. ただし, VT・VF クラスが多く集まるクラスタ0 には, N・AF が2割近く含まれてしまっている. これらを解釈するためにクラスタ0 に含まれる N・AF の心電波形画像を確認した. 図 5.10 に K=2 においてクラスタ0 に含まれる N・AF ラベルの心電波形画像の例を示す. 図の左の二つの画像が N ラベルの心電波形画像で, 右の二つが AF ラベルの心電波形画像である. 図 5.10 より, N ラベル, AF ラベルのいずれの画像もノイズが大きいあるいは, 歪みや波形の反転などがみられる. クラスタ1 の心電波形画像を確認したところ大きなノイズや歪みは比較的少ないことが確認できた. よって, これらのノイズや歪みが, VT・VF クラスのクラスタであると誤認識する要因の一つであると推察される.




図 5.10 K=2 においてクラスタ0 に含まれる N・AF ラベルの心電波形画像の例

K=3 のクラスタリング結果 (図 5.2 図 5.3) において, クラスタ-0 が N・AF ラベルのクラスタであり, クラスタ-1 が VT・VF ラベルのクラスタとなった. また, いずれのクラスラベルも多く含むクラスタ-2 が現れた. 以下において, クラスタ-2 に含まれる心電波形画像を他のクラスタの同一ラベルの心電波形画像と比較する.

図 5.11, 図 5.12 に K=3 におけるクラスタ-0 とクラスタ-2 の N ラベルの比較を示す. それぞれの図の上部がクラスタ-0, 下部がクラスタ-2 の心電波形画像である. 図 5.11 よりクラスタ-2 へと分類された N ラベルの心電波形には R 波の反転がみられることが分かる. しかし, クラスタ-2 へと分類された N ラベルの心電波形には, 図 5.12 に示すようにクラスタ-0 に含まれるものとの違いが明確でないものも一部存在し, 解釈が困難であった.




図 5.11 K=3 におけるクラスタ-0 とクラスタ-2 の N ラベルの比較 (1)




図 5.12 K=3 におけるクラスタ-0 とクラスタ-2 の N ラベルの比較 (2)

次に, 図 5.13 に K=3 におけるクラスタ-0 とクラスタ-2 の AF ラベルの比較を示す. 図の左二つの画像がクラスタ-0, 右二つがクラスタ-2 の AF ラベル心電波形画像である. AF ラベルの画像については, ノイズや波形の歪みが大きいものがクラスタ-

2へと分類されていることが、図 5.13 より分かる。




図 5.13 K=3 におけるクラスター0 とクラスター2 の AF ラベルの比較

また、図 5.14 に K=3 におけるクラスター1 とクラスター2 の VF ラベルの比較を示す。VF ラベルの心電図については、波形の振幅が比較的小さいものが、クラスター2 へと分類される傾向が見られた。VT ラベルの画像についても同様の傾向がみられた。




図 5.14 K=3 におけるクラスター1 とクラスター2 の VF ラベルの比較

K=3 において、いずれのラベルクラスにも属さないクラスター2 は、歪みやノイズの多い N・AF ラベルの心電図および、振幅が比較的小さい VT・VF ラベルの心電波形画像を多く含むことがわかった。歪みやノイズの多い N・AF ラベルのデータは VT・VF の特徴に引きずられたと推察される。また、N・AF ラベルのデータは、R 波以外の波形ピークの振幅が小さいため、これらの特徴が振幅の小さい VT・VF を同じグループへと包含する要因になったと考えられる。心電図波形のアノテーションにおいては、ノイズや歪み、振幅の違いなどがあっても、正確に真の心電波形クラスへとラベル付ける必要がある。K=3 でのクラスタリングでは、多数の心電波形クラスを含むクラスター2 が出現し、この要件を満たせないことが分かる。

次に、K=4 におけるクラスタリング結果について考察を行う。図 5.3 より、クラス

ター0 およびクラスター1 が N・AF ラベルのクラスターであり、クラスター2 およびクラスター3 が VT・VF ラベルのクラスターであることが分かる。真の心電波形クラスが N・AF・VT・VF の 4 つであるため、各々のクラスターに分かれることを期待したが、そのようにはならず、実質的に、似た心電図同士の二つのグループ (N・AF グループ、VT・VF グループ) へと分離した。K=2 の時には、VT・VF ラベルのクラスターに 2 割程度の N・AF ラベルのデータが混ざってしまっていたが、K=4 の場合はその割合は 1 割に満たないことが図 5.3 より分かる。また、K=3 の場合と比較すると、K=3 の時にすべてのラベルの混合クラスターであるクラスター2 に分類されていたものが、K=4 では N・AF あるいは VT・VF のいずれかのグループへとより正確に分類されているといえる。K=3 においてクラスター2 (すべてのラベルの混合クラスター) であったものが、K=4 ではどのクラスターへと分類されたかを調べた。その結果、K=3 のクラスター2 の N・AF ラベルの心電波形画像は K=4 のクラスター1 へ、K=3 のクラスター2 の VT・VF ラベルの心電波形画像は K=4 のクラスター3 へと多く分類される傾向が見られた。よって、K=4 のクラスター0 とクラスター1 は同じ N・AF ラベルのクラスターであるが、これらの違いの一つとして、ノイズや歪みの程度が異なることが挙げられる。また、K=4 のクラスター2 とクラスター3 (どちらも VT・VF ラベルのクラスター) の違いの一つは、心電図波形の振幅の大きさにあると考えられる。アノテーション支援の観点から述べると、K=4 では、N・AF グループに属するか、VT・VF グループに属するかの 2 つの示唆しか与えられないため、アノテーション支援への効果は極めて小さいと言える。特に、正常波形である N ラベルデータと不整脈である AF ラベルデータが同じグループとして提示されると、これら二つのラベルデータは区別が難しいものも多いため、アノテーション実施者自身が、どちらのラベルを付けるべきかの判断を行わなくてはならず、作業者の負担軽減には繋がらない可能性が高い。

N および AF が明確に分離し始めるのは、K=8 の時であった (図 5.7)。特に、K=8 におけるクラスター7 はほぼ全てが N ラベルをもつデータであり、そのクラスター内での N ラベルの割合は 9 割を大きく超えている。また、クラスター3 についてみると、区別が極めて難しい VT・VF ラベルの波形のうち、VT ラベルの心電波形画像を多く抽出することができることが分かる。また、K=8 において、被験者ごとに心電図データがクラスタリングされていないかを調べた。これは、心電波形の個人差が大きいことによって、個人の波形に依存したクラスタリングが行われてしまっていないかを確認するためである。その結果、いずれのクラスターも複数の被験者の心電図波形を含み、同一被験者の心電波形であっても、複数のクラスターへと分類されていることがわかった。ただし、クラスター3 は 1 人の被験者の心電波形画像が 55.5% を占めているため、VT ラベルの抽出の再現性は低いと思われる。N ラベルのクラスターであるクラスター7 は様々な被験者の心電波形データから成り、同一被験者の心電波形画像の割合は高くとも 1 割程度であった。よって、クラスター7 においては N ラベルの心電波形画像の抽出に

成功していると言える。また、クラスター4, 5については、依然として他のラベルクラスをもつ心電波形画像が混ざっているとはいえ、AF ラベルの心電波形画像が8割程度を占めており、クラスター5に至っては8割以上となっている。K=8のクラスタリング結果をまとめると、表5.2のようになる。クラスター0およびクラスター7は正常波形が8割以上を占めるため、正常波形グループとした。クラスター1およびクラスター6はVT・VFの混合グループであり、両ラベルとも心室性の不整脈であるため、心室性不整脈グループであるといえる。クラスター2, クラスター4, クラスター5の3つのクラスターはAFグループすなわち心房性の不整脈のグループである。クラスター3については、信頼性が低いもののVTグループとされる。アノテーション支援の際は、これらのグループをラベルとしてアノテーション作業員へと提示することで、アノテーションの補助を行うことができると考えられる。その際に、クラスタリングで振り分けられたクラスターごとに信頼度を設定することで、ラベルの提示をより効果的に行うことができると思われる。

表 5.2 K=8のクラスタリング結果のまとめ

クラスター0, クラスター7	Nグループ (正常波形グループ)
クラスター1, クラスター6	VT・VFグループ (心室性不整脈グループ)
クラスター2, クラスター4, クラスター5	AFグループ (心房性不整脈グループ)
クラスター3	VTグループ

K=9およびK=10のクラスタリング結果(図5.8, 図5.9)については、K=8の時よりもラベルクラスの分離率が高くなるようなクラスターは出現せず、同一被験者の心電波形画像が同一クラスターへと密集しやすくなる傾向が見られた。実験的にK=16におけるクラスタリングの傾向を観察したが、3つのクラスターで同一被験者の心電波形画像が5割を超えるという結果となった。

以上より、心電波形のアノテーション支援に効果的なクラスター数Kは、8であることが本実験の結果から示唆された。

本研究では、画像データを用いて教師なしクラスタリングを行なったが、比較のために、心電波形の信号データに対してもクラスター数K=8として実験を行なった。ただし、IMSATで用いるResNet50の畳み込み層は1次元畳み込み層であり、事前学習はされていない。また、用いたハイパーパラメータは画像データのクラスタリングの場合と同じとした。図5.15に心電波形信号に対するクラスタリング結果(K=8)を示す。画像データを用いた場合よりも、AFラベルをもつデータの抽出がうまくいっていないこ

とが分かる。画像データを用いた場合の方が、良い結果が得られる理由の一つとして、モデルの事前学習が挙げられる。次元信号データに対する事前学習モデルは例が少なく、本研究で用いたモデルについては、画像のような大量のデータを事前に学習させておくといった事前学習の恩恵を受けることができていない。これにより、画像データほど細かい特徴を学習過程にて抽出することができなかつたと考えられる。また、IMSATは本来、画像データに対して考案された手法であることや、画像データのほうが正則化手法の幅が広いといった理由から、心電波形信号の画像データへの変換は効果的であったと考えられる。




図 5.15 心電波形信号に対するクラスタリング結果 (K=8)

5.4 教師なしクラスタリング まとめ

本研究では、教師なしクラスタリング手法である IMSAT を用いて、心電波形画像のクラスタリングを行なった。その結果、クラスタリング数 $K=8$ において、アノテーション支援へと応用が可能であると考えられるクラスターが得られた。それらのクラスターは、心電波形を主に3つのグループ（正常波形、心室性不整脈、心房性不整脈）へと分類するものであった。心電波形画像が分類されるクラスターごとに信頼度などの指標を設定することで、効果的なアノテーション支援が可能であると考えられる。

本研究では、画像に対して CNN をベースとする機械学習手法を用いたが、信号データに対して RNN や Attention などを用いた手法や、周波数分解などのデータ変換などを使用したモデルを画像分類モデルへとアンサンブルさせることで、モデル性能を向上させることが期待できる。また、IMSAT のネットワーク構造として ResNet50 を採用していたが、近年では ResNet50 よりも性能が高く、パラメータ数も少ないネットワーク [44] も公開されている。これらの予測手法やネットワーク構造を検討することで、本研究領域の今後のさらなる発展が期待できる。

第6章 総括

心電波形の自動分類などで用いられる教師あり機械学習は、データにアノテーションがない場合やデータが少ない場合には、実施できないあるいは十分な性能が期待できない。そのため、ラベル付きデータが少数になりがちである心電波形データに適用するには、膨大なアノテーション作業を行わなくてはならないという課題がある。本研究では、心電波形データに対するアノテーションの補助、不整脈診断補助を目的に、半教師あり学習および教師なしクラスタリングの有用性検証や、それらの手法をより効果的にする Data Augmentation 手法の検証を行なった。

本研究の半教師あり学習手法の有効性検証は、少数のラベル付きデータしか得られていない場合に、データへと自動でアノテーションを行うことを目指したものである。本研究では、少数のラベル付きデータから、ラベルを予測するために VAT と Entropy Minimization とを組み合わせた手法を提案した。結果として、教師ありデータが少数（およそ 16~32 サンプル）である場合には提案手法によって、通常の教師あり学習よりも精度の高い分類を行うことができた。症例の観測が難しい不整脈については、データを多く収集することは困難であるため、本手法の有効性は高いと言える。

また、半教師あり学習の性能を向上させることを期待し、VAE によるデータの水増しが可能か否かを検証した。本研究では、性能向上につながるような、精密な心電波形を生成することはできなかったが、心電波形の大まかな形状などを捉えた波形を生成することには成功したため、RNN や Attention などの波形の前後の形状を表現しやすいモデルを活用することで、今後さらに精密な心電波形を生成することができるようになると思われる。

教師なしクラスタリング手法による知見創出・アノテーション補助では、IMSAT を用いて解釈可能な3つのグループを得ることができた。新たな知見創出には繋がらなかったが、これらの3つのグループをアノテーション補助へと応用することは十分に可能であると思われる。

一方で、半教師あり学習・教師なし学習ともに、依然として VT・VF を明確に分離するような分類を行うことができなかった。今後、これらの微細な違いを捉えられるような前処理手法や分類手法が提案されることを期待する。

謝辞

本研究を進めるにあたり、たいへん多くの方々から御指導、御協力をしていただきました。数々の丁寧な御指導や、大変恵まれた研究環境を与えてくださった奈良先端科学技術大学院大学 先端科学技術研究科 金谷 重彦 教授に心より感謝いたします。度重なる議論を通して賜りました、統計学や機械学習に関する知見は、研究を遂行する上での重要な資本となりました。

研究発表や修士論文執筆の際に、副指導教員として貴重な御意見を賜りました、奈良先端科学技術大学院大学 先端科学技術研究科 笠原 正治 教授、峠 隆之 准教授に感謝の意を表します。

また、本研究を進めるにあたり、副指導教員として思慮深い御助言を与えてくださいました奈良先端科学技術大学院大学 先端科学技術研究科 黄 銘 助教に深く感謝いたします。

研究室のゼミナールにおいては、真摯に御指導いただきました奈良先端科学技術大学院大学 先端科学技術研究科 Md. Altaf-Ul-Amin 准教授、小野 直亮 准教授に厚く御礼申し上げます。

また、研究活動をするにあたって様々な面で支えてくださった、同研究室の方々および修了生の皆様に深謝の意を表します。特に、心電図に関する様々な知見をくださった同研究室 博士後期課程 城戸 孝士郎 氏や、研究活動に関わる諸手続き等で御対応くださった秘書・研究員の方々に大変深く感謝申し上げます。日々の対話の中で、分野にこだわらず幅の広い議論をしてくださった同期・後輩の皆様にも、再度、心から御礼申し上げます。

最後に、私の大学院生活を温かく見守ってくださった祖父母含め、家族に感謝の意を表し、ここに謝辞とさせていただきます。

参考文献

- [1] 厚生労働省, “平成 29 年 (2017) 人口動態統計 (確定数) の概況: 統計表第 6 表,” 2018.
- [2] W. H. Organization, “The top 10 causes of death,” 2018.
- [3] 厚生労働省, “平成 29 年度 国民医療費の概況,” 2019.
- [4] 城戸孝士郎, “容量結合心電計を用いた睡眠時異常心拍検出システムの構築,” 奈良先端科学技術大学院大学 修士論文, 2018.
- [5] 小沢友紀雄ら, “やさしい心電図の見方,” トーアエイヨー株式会社, 2014.
- [6] F. E. Olvera, “Electrocardiogram waveform feature extraction using the matched filter,” *ECE SIO Stat Proc*, **2**(1), 13-34(2016).
- [7] W. Chen, Z. Mo , W. Guo, “Detection of QRS Complexes Using Wavelet Transforms and Golden Section Search,” *International Conference on Intelligent Systems and Knowledge Engineering*, 2007.
- [8] A. Mostayed, J. Luo, X. Shu , W. Wee, “Classification of 12-Lead ECG Signals with Bi-directional LSTM Network,” *arXiv:1811.02090*, 2018.
- [9] L. Guo, G. Sim , B. Matuszewski, “Inter-Patient ECG Classification with Convolutional and Recurrent Neural Networks,” *Biocybernetics and Biomedical Engineering*, **39**, 868-879 (2019).
- [10] P. Rajpurkar, A. Y. Hannun, M. Haghpanahi, C. Bourn , A. Y. Ng, “Cardiologist-Level Arrhythmia Detection with Convolutional Neural Networks,” *Nat Med*. **25**, 65-69(2019).
- [11] A. L. Goldberger, L. A. Amaral, L. Glass, J. M. Hausdorff, P. C. Ivanov, R. G. Mark, J. E. Mietus, G. B. Moody, C.-K. Peng , H. E. Stanley, “PhysioBank, PhysioToolkit, and PhysioNet Components of a New Research Resource for Complex Physiologic Signals,” *Circulation* **101**(23), 215-220(2000).
- [12] G. B. Moody , R. G. Mark, “The Impact of the MIT-BIH Arrhythmia Database,” *IEEE Engineering in Medicine and Biology* **20**(3), 45-50(2001).
- [13] G. SD., “The development and analysis of a ventricular fibrillation detector,” Thesis (M.S.) Massachusetts Institute of Technology, Dept. of Electrical Engineering and Computer Science, 1986.
- [14] 亀井靖高, “オーバーおよびアンダーサンプリング法を用いた Fault-prone モジュール判別モデルの精度評価,” 奈良先端科学技術大学院大学情報科学研究科 修士論文, 2007.

- [15] T. Miyato, S. Maeda, M. Koyama, K. Nakae, S. Ishii, “DISTRIBUTIONAL SMOOTHING WITH VIRTUAL ADVERSARIAL TRAINING,” ICLR, 2016.
- [16] T. Miyato, S. Maeda, M. Koyama, S. Ishii, “Virtual Adversarial Training: A Regularization Method for Supervised and Semi-Supervised Learning,” arXiv: 1704.03976v2, 2018.
- [17] Y. Grandvalet, Y. Bengio, “Semi-supervised Learning by Entropy Minimization,” NIPS, 529-536(2004).
- [18] A. Oliver, A. Odena, C. Raffel, E. D. Cubuk, I. J. Goodfellow, “Realistic Evaluation of Deep Semi-Supervised Learning Algorithms,” NeurIPS, 2018.
- [19] I. J. Goodfellow, J. Shlens, C. Szegedy, “EXPLAINING AND HARNESSING ADVERSARIAL EXAMPLES,” ICLR, 2015.
- [20] C. Szegedy, W. Zaremba, I. Sutskever, J. Bruna, D. Erhan, I. Goodfellow, R. Fergus, “Intriguing properties of neural networks,” arXiv preprint arXiv:1312.6199, 2013.
- [21] G. H. Golub, H. A. Vorst, “Eigenvalue computation in the 20th century,” Journal of Computational and Applied Mathematics **123**, 35-65(2000).
- [22] K. He, X. Zhang, S. Ren, J. Sun, “Deep residual learning for image recognition,” CVPR, 770-778(2016).
- [23] D. Kingma, J. Ba, “Adam: A method for stochastic optimization,” ICLR, 2015.
- [24] H. Zhang, M. Cisse, Y. N. Dauphin, D. L. Paz, “mixup: BEYOND EMPIRICAL RISK MINIMIZATION,” ICLR, 2018.
- [25] D. Berthelot, N. Carlini, I. Goodfellow, N. Papernot, A. Oliver, C. Raffel, “MixMatch: A Holistic Approach to Semi-Supervised Learning,” NeurIPS, 2019.
- [26] D. Berthelot, N. Carlini, E. D. Cubuk, A. Kurakin, K. Sohn, H. Zhang, C. Raffel, “REMIXMATCH: SEMI-SUPERVISED LEARNING WITH DISTRIBUTION ALIGNMENT AND AUGMENTATION ANCHORING,” arXiv:1911.09785, 2019.
- [27] S. Hochreiter, J. Schmidhuber, “Long Short-Term memory,” Neural computation, 1997.
- [28] K. Cho, B. v. Merriënboer, C. Gulcehre, D. Bahdanau, F. Bougares, H. Schwenk, Y. Bengio, “Learning Phrase Representations using RNN Encoder-Decoder for Statistical Machine Translation,” arXiv:1406.1078, 2014.
- [29] A. Vaswani, N. Shazeer, N. Parmar, J. Uszkoreit, L. Jones, A. N. Gomez, L. Kaiser, I. Polosukhin, “Attention Is All You Need,” NIPS, 2017.
- [30] Q. Yao, R. Wang, X. Fan, J. Liu, Y. Li, “Multi-class Arrhythmia detection from 12-lead varied-length ECG using Attention-based Time-Incremental Convolutional Neural Network,” Information Fusion **53**, 174-182(2020).

- [31] D. P. Kingma , M. Welling, “Auto-Encoding Variational Bayes,” arXiv:1312.6114, 2013.
- [32] C. Doersch, “Tutorial on Variational Autoencoders,” arXiv:1606.05908, 2016.
- [33] C. H. Tien, H. Y. Yen, F. S. Wei, H. K. Hsuan, T. Yu , C. S. Yi, “Noise Reduction in ECG Signals Using Fully Convolutional Denoising Autoencoders,” IEEE Access 7, 60806-60813(2019).
- [34] G. E. Hinton , R. R. Salakhutdinov, “Reducing the Dimensionality of Data with Neural Network,” Science 313, 504-507(2006).
- [35] J. Paisley, D. Blei , M. Jordan, “Variational Bayesian Inference with Stochastic Search,” ICML, 1363-1370(2012).
- [36] I. J. Goodfellow, J. P. Abadie, M. Mirza, B. Xu, D. W. Farley, S. Ozair, A. Courville , Y. Bengio, “Generative Adversarial Nets,” arXiv:1406.2661, 2014.
- [37] L. Dinh, D. Krueger , Y. Bengio, “ NICE: NON-LINEAR INDEPENDENT COMPONENTS ESTIMATION,” ICLR, 2015.
- [38] D. P. Kingma , P. Dhariwal, “Glow: Generative Flow with Invertible 1x1 Convolutions,” arXiv:1807.03039, 2018.
- [39] A. B. L. Larsen, S. K. Sønderby, H. Larochelle , O. Winther, “Autoencoding beyond pixels using a learned similarity metric,” arXiv:1512.09300, 2015.
- [40] A. v. d. Oord, S. Dieleman, H. Zen, K. Simonyan, O. Vinyals, A. Graves, N. Kalchbrenner, A. Senior , K. Kavukcuoglu, “WaveNet: A Generative Model for Raw Audio,” arXiv:1609.03499, 2016.
- [41] W. Hu, T. Miyato, S. Tokui, E. Matsumoto , M. Sugiyama, “ Learning Discrete Representations via Information Maximizing Self-Augmented Training, ” arXiv:1702.08720, 2017.
- [42] A. Krause, P. Perona , R. G. Gomes, “ Discriminative Clustering by Regularized Information Maximization,” NIPS, 2010.
- [43] Y. Wu, F. Yang, Y. Liu, X. Zha , S. Yuan, “A Comparison of 1-D and 2-D Deep Convolutional Neural Networks in ECG Classification,” arXiv:1810.07088, 2018.
- [44] M. Tan , Q. V. Le, “EfficientNet: Rethinking Model Scaling for Convolutional Neural Networks,” ICML, 2019.