

心電図からの心房細動の検出方法

秋田大学 大学院理工学研究科
数理・電気電子情報学専攻
准教授 田中 元志

2022年3月3日

背景と目的・課題

心房細動 (AF, Atrial Fibrillation)

- … 異常な電氣的興奮によって
心房が300～600回収縮する
不整脈の一種
脳梗塞, 心不全, 心筋梗塞の原因となる

日本における心房細動の罹患者 … 約100万人とされる
心房細動の罹患者の割合は年々増加傾向^[1]

心房細動の自動検出 ⇒ 医療現場への貢献が期待される

[1] 赤尾: 日本内科学会雑誌, **108**(2), 196–203 (2019).

心房細動 (AF)

危険度 ↓	発作性	… 一時的な心房細動, <u>数分～数時間程度</u> で終了) 放置
	持続性	… 発作が <u>1週間以上</u> 継続	
	慢性	… 発作が <u>長期(1年以上)</u> にわたって継続, 薬剤治療を行っても完全に治療するのが困難) 放置

発作性心房細動は自覚症状がないことが多く, 放置されやすい
放置すると持続性, 慢性へと移行^[1]



脳梗塞・心不全等のリスク増

□ 発作性心房細動の早期発見が重要


⇒ 健康診断やホルター心電図の大量データから検出したい

👉 2019よりモリーオ(株)と共同研究

[1] 心房細動とは? https://doctorblackjack.net/about_heart_trouble/ope_index_05.html, (2021-02-01 閲覧)

心房細動の心電図における特徴


- ① RR間隔が不規則
- ② P波が認められない
- ③ 不規則な基線の動揺(f波)が認められる



正常な心電図




通常は①の特徴を利用して
不整脈区間を検出し、
心房細動の診断を行う

②③の特徴：
定量的に表すことができない
↓
どのようにして特徴を捉えるか
👉 課題




心房細動発生時の心電図

周波数スペクトルの比較



正常波形のスペクトル例



異常波形(心房細動)のスペクトル例

- 周波数スペクトルに違いが見られる

スペクトルエントロピー(SE: Spectral Entropy)

- 信号の周波数パワー分布を表す尺度
- 信号のスペクトル包絡が平坦なほど大きな値をとる

心電図波形分類への利用事例あり^[1] ⇒ 正常異常判定への利用の可能性

[1] A Asgharzadeh-Bonab, et al, *Biocybernetics and Biomedical Engineering*, **40**(2), 691-700(2008).

従来の検討と課題①

画像のパターン認識に強いとされるたたみ込みニューラルネットワーク (CNN) を利用した検討が多い

< 先行研究の例 >

- 心電波形を数秒間に分割して **1次元CNN** で学習^[1]
 - ✓ テストデータの検出精度: 90.5%
- 心電波形のスペクトログラムを **2次元CNN** で学習^[2]
 - ✓ 学習データのみの検出精度: 98.7%

しかし、多くは**12誘導心電図**を対象

波形は良好であるが、記録時間が**短い**(数10秒～数分)

⇒ 発作性心房細動の発見が難しい

- 精密な検査では**24時間計測のホルター心電図**を使用
- **誤検出の低減, 精度向上が求められる**


[1] U.Erdenebayar, et al, *J Korean Med. Sci.*, **34**(7): e64, (2019).

[2] M.Zihlmann, et al, *2017 Computing in Cardiology* (Rennes, France), 4 pages (2018).

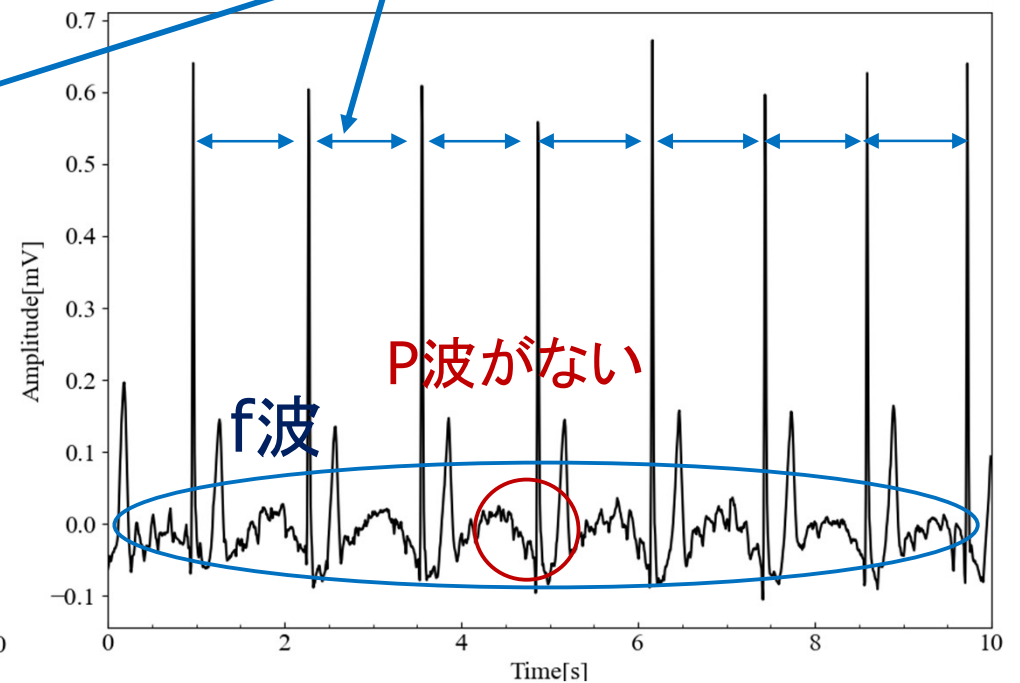

課題② RR間隔が規則的な心房細動がある

□ 心房細動(AF)の特徴

- ① RR間隔が不規則
- ② P波がない
- ③ 基線の動揺(f波)がある



RR間隔(心拍)は一定

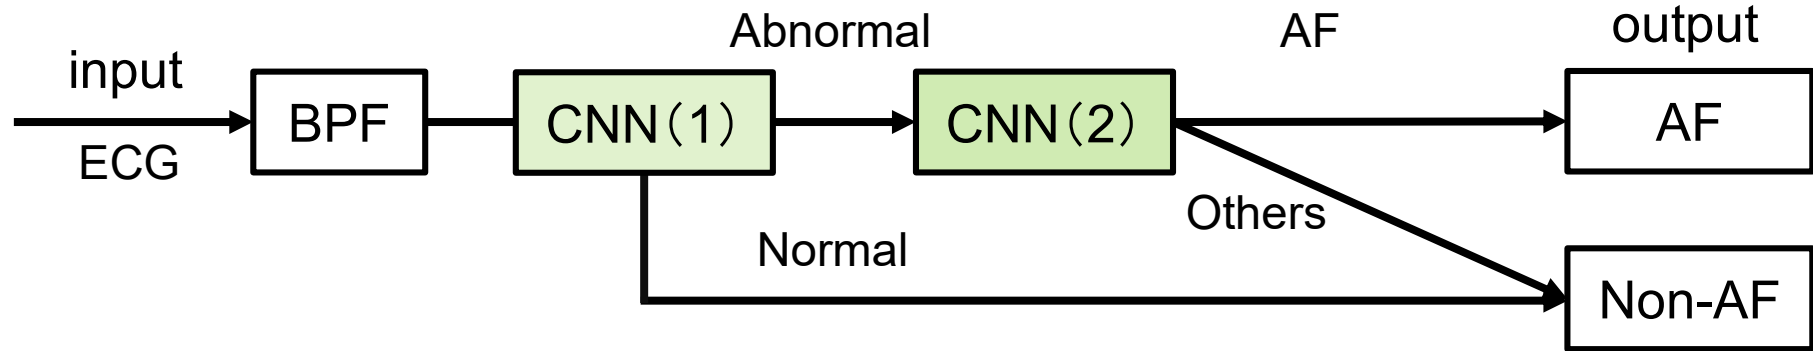


RR間隔のみに注目した場合：正常と判別してしまう

⇒ ②③の特徴(定性的な特徴)の利用が**重要**

提案する心房細動検出方法

異なる2つのCNNによる2段階構成で心房細動を検出



□ BPF

- 帯域通過フィルタ(1-30 Hz)を用いて体動等によるアーチファクトを除去

□ CNN(1)

- 波形の正常異常を判定し, 異常波形を抽出
(期外収縮や心房細動など)

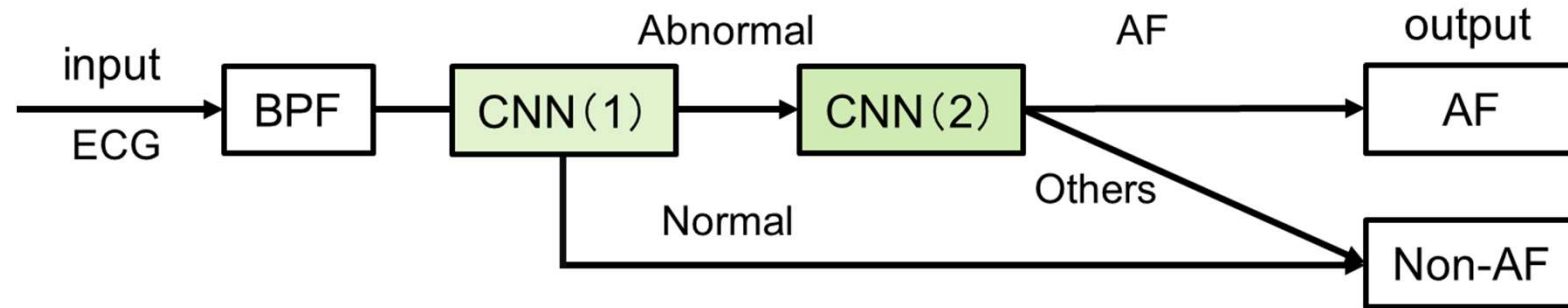
□ CNN(2)

- 抽出された異常波形から心房細動を識別

提案方法の特徴

■ 2段構成による心房細動の検出

⇒ 心電波形の正常異常判定を先に行うことで誤認識を減らす



■ 規則的なRR間隔をもつ心房細動の検出の可能性


⇒ 不整脈区間の診断では見落とされる心房細動を検出できる可能性

① BPFを用いた波形のノイズ除去


□ FIR帯域通過フィルタ(BPF)の設計

👉 フィルタの振幅応答


- 通過帯域 1-30 Hz
- カイザー窓
- 2956次



● 心電図(128 Hzサンプリング)の前処理の例



👉 生波形



👉 前処理後の波形

② CNN(1): 異常波形の抽出

■ パワースペクトログラム $S(t, f)$ の算出

FSST (Fourier Synchro Squeezed Transform)^{[1][2]}を利用

- 窓によって広がったスペクトル成分を押し込めることで時間-周波数平面を再構成する手法
- パワースペクトログラムの時間分解能は、心電波形のそれと等しい

■ スペクトルエントロピー(SE)の算出

- 信号の白色性を表す特徴量
- 信号の周波数分布が平坦であるほど、大きな値をとる

解析条件

窓関数	カイザー窓 ($\alpha = 10$)
窓長	1.0 s
ポイント数	2^7

$$S_e(t) = \sum_f I(t, f)$$

$$p(t, f) = \frac{S(t, f)}{\sum_f S(t, f)} \quad : \text{パワー存在確率}$$

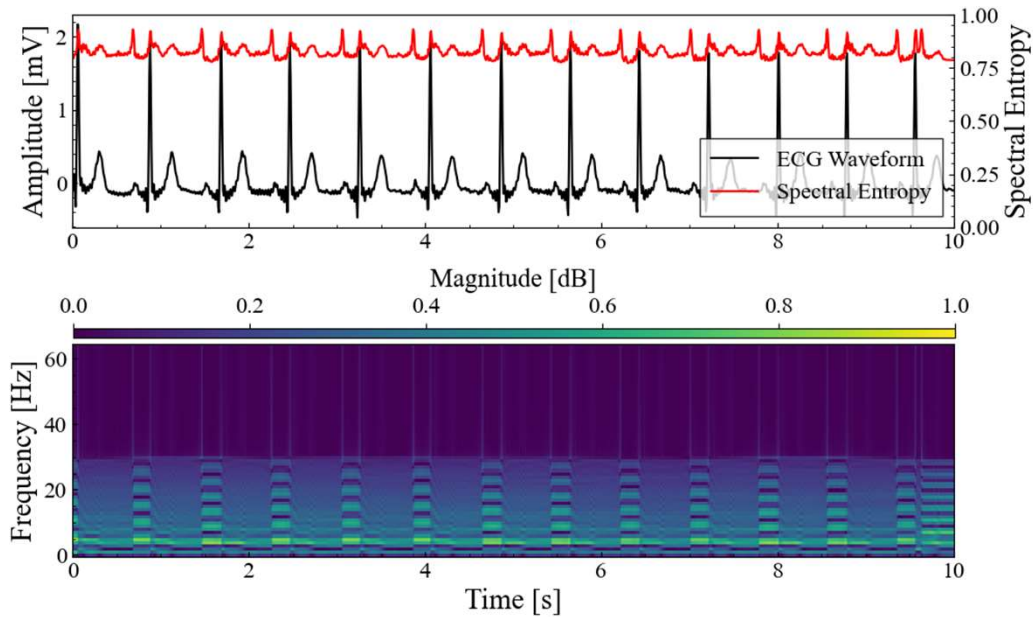
$$I(t, f) = -p(t, f) \log_2 p(t, f) \quad : \text{周波数パワーの自己情報量}$$

[1] F. Auger, et al.: *IEEE Signal Processing Magazine*, **30**, 32–41(2013).

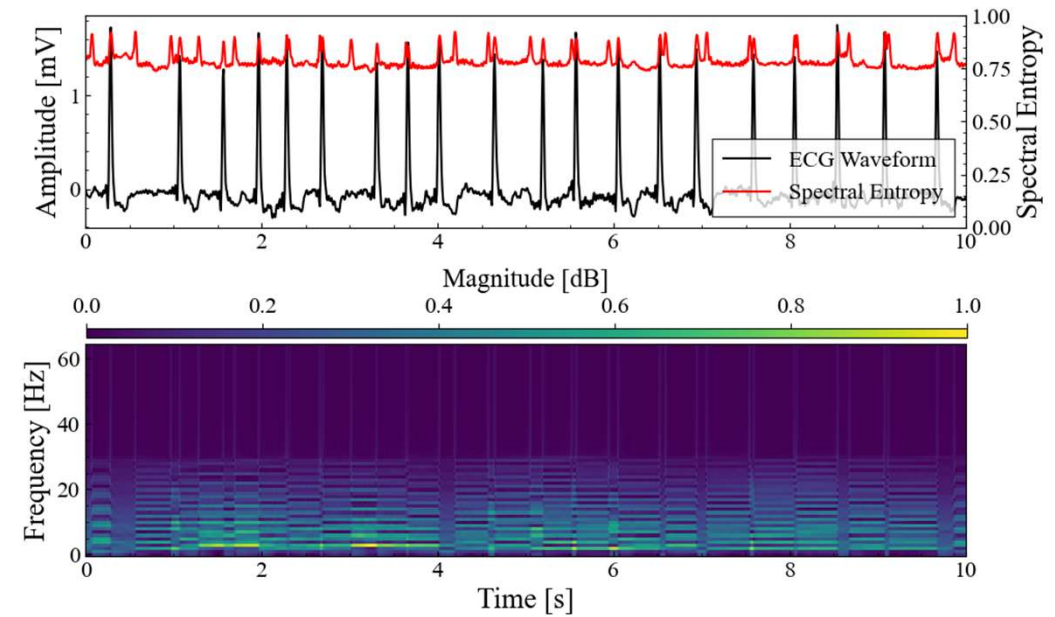
[2] T. Oberlin, et al, *IEEE ICASSP*, 315–319(2014).

SEの例と学習用データ

＜正常波形＞



＜異常(心房細動)波形＞



算出結果例(下:スペクトログラム, 上:心電図とSE)


■ 学習データの作成

● 心電波形: $x' = \frac{x_i - x_{min}}{x_{max} - x_{min}}$

● SE: $SE' = \frac{SE_i}{\log_2(1 + f_s/2)}$

👉 正規化

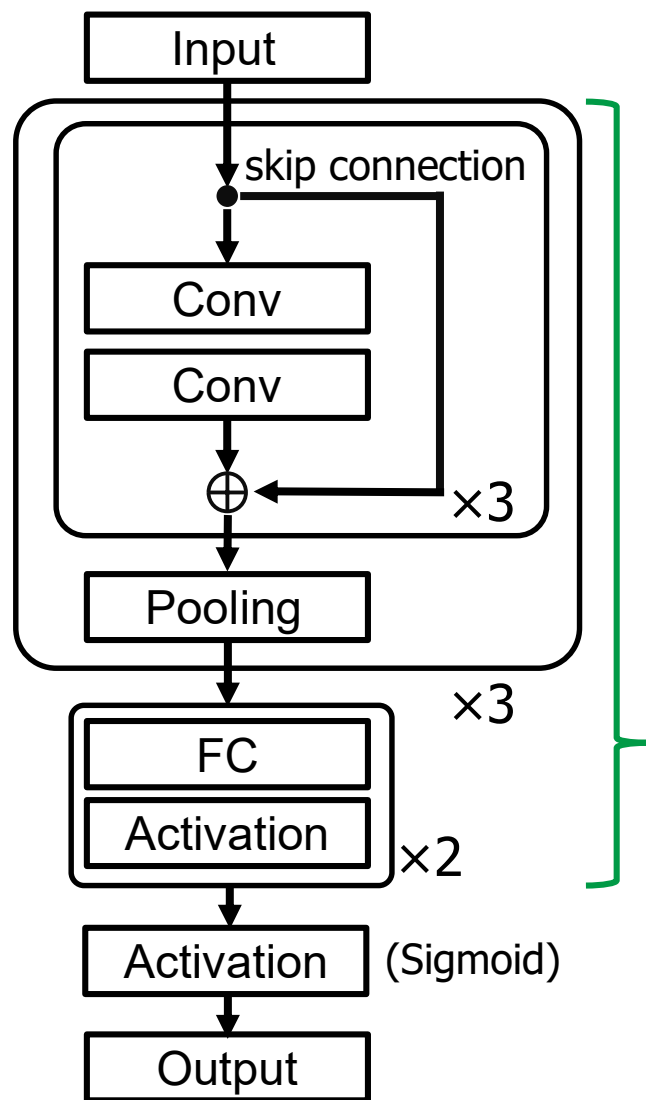
組み合わせる



👉 学習データ

CNN(1)の学習結果

● ResNet^[1]型の1次元CNN



畳み込み層: 31層

全結合層: 2層

■ 学習データ数

Class	Number of data
Normal	18280
Abnormal	29240
Total	47520

□ 学習と検証方法

- 学習回数: 16
- 全データのうち75%を学習用, 25%を検証用として使用

■ 学習結果

- ✓ 学習データにおける精度: 100.0%
- ✓ 検証データにおける精度: 99.3%

[1] K. He, et al., *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*, 770-778(2016).

③ CNN(2): 心房細動の識別

■ 学習データとしてスペクトログラム(Spectrogram)を用いる

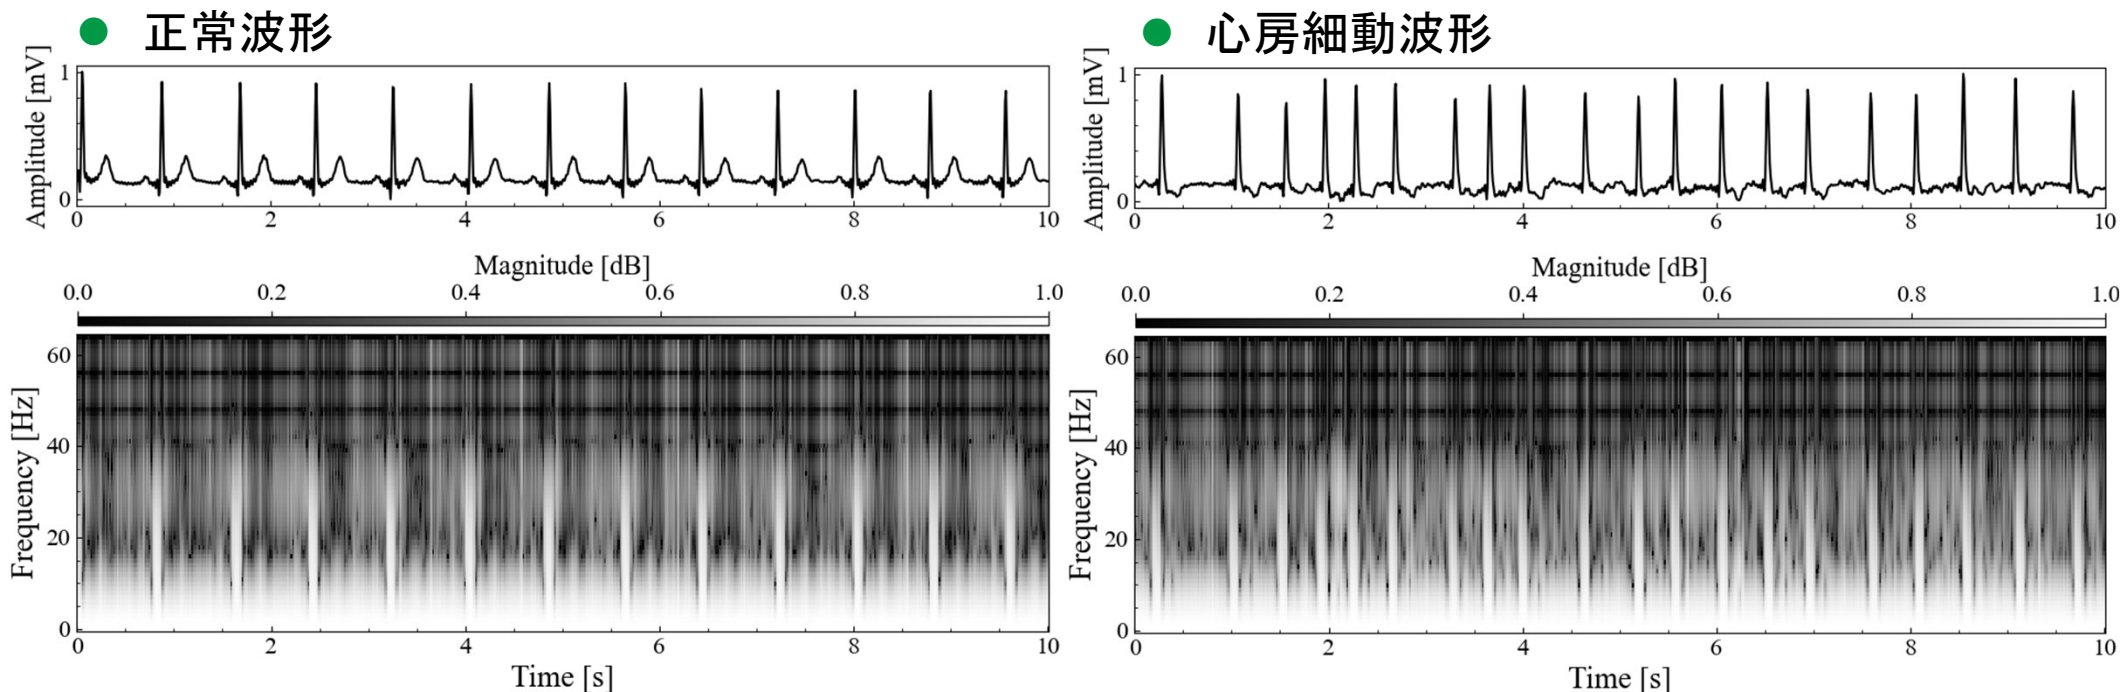
□ 短時間フーリエ変換による時間-周波数解析

- 周波数成分の時間変化を利用

解析条件


窓関数	ハミング窓
窓長	0.14 s
FFTポイント数	2 ⁷
シフト幅	0.1 s

👉 各スペクトルに違い



スペクトログラムの算出例

CNN(2)における判別方法



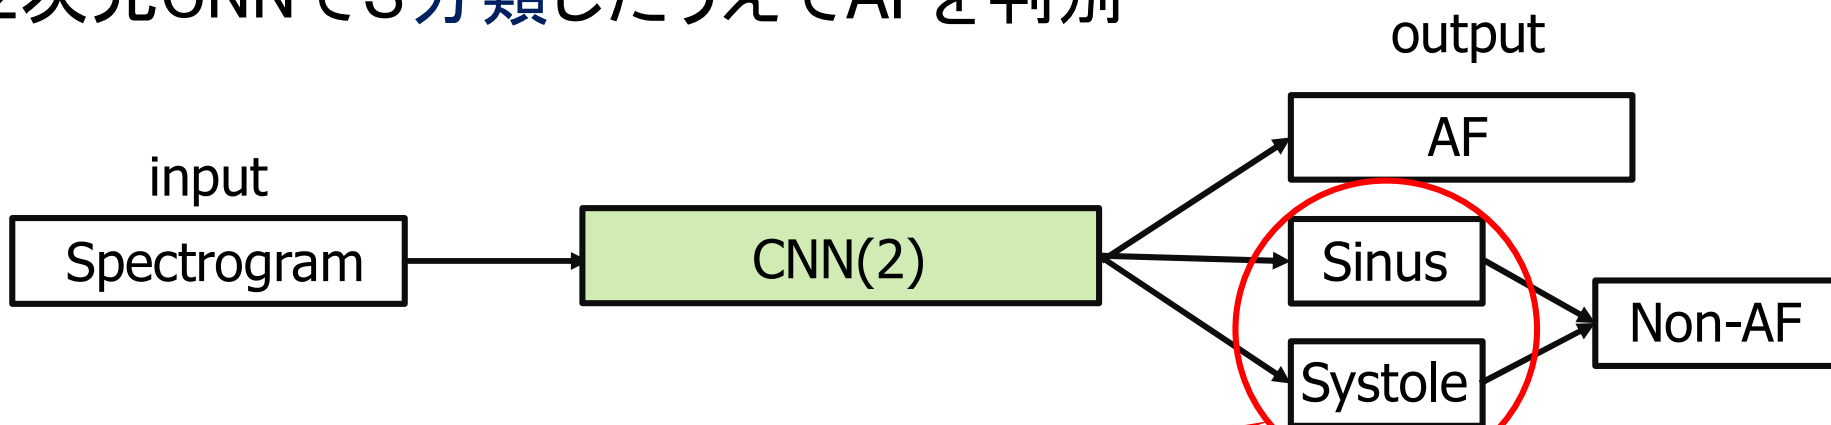
正常

期外収縮

- 正常波形と期外収縮のスペクトルは異なる



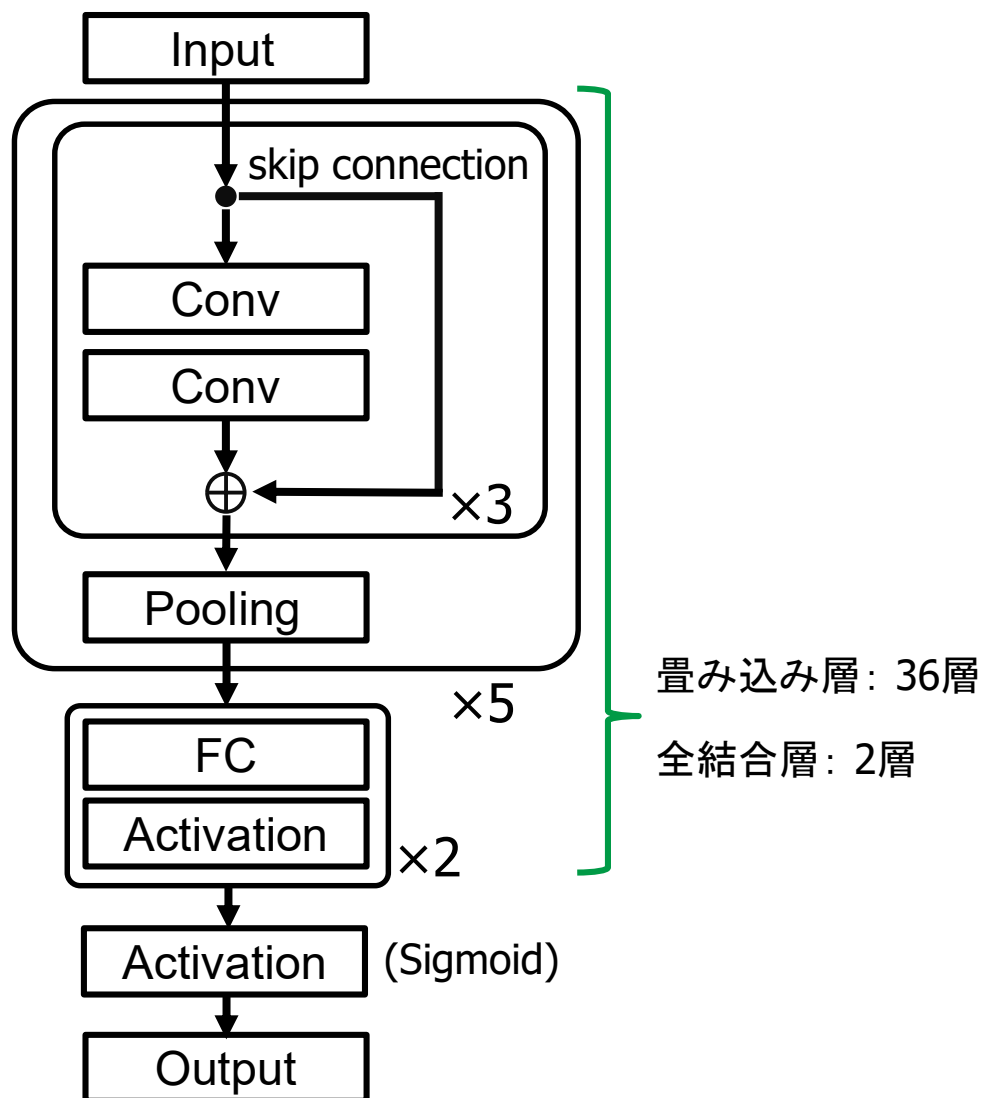
- 2次元CNNで3分類したうえでAFを判別



3分類後「AF以外」に統合する = 実質2分類

CNN(2)の学習

● ResNet^[1]型の2次元CNN



■ 学習データ数

Class	Number of data
AF	22950
Others	24570
Total	47520

□ 学習と検証方法

- 学習回数: 35
- 全データのうち75%を学習用, 25%を検証用として使用

■ 学習結果

- ✓ 学習データにおける精度: 100.0%
- ✓ 検証データにおける精度: 98.0%

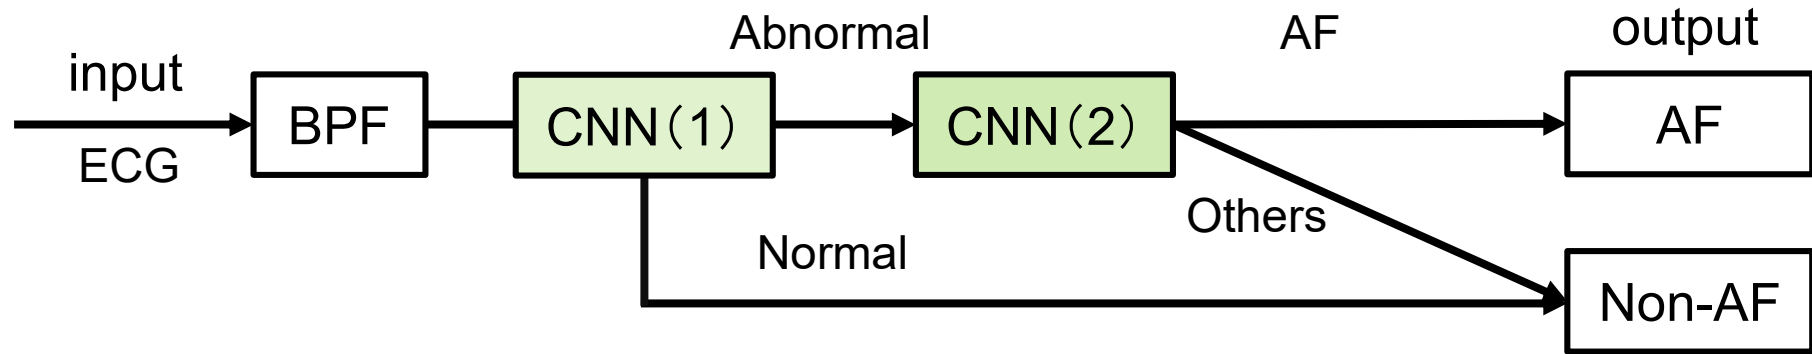
[1] K. He, et al., *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*, 770-778(2016).

心房細動の検出(未学習データを用いた実験)

■ テストデータ(未学習)

- ホルター心電図(10名分)
- MIT-BIHデータベース(心電図の公開データベース)

G. B. Moody, et al., *IEEE Engineering in Medicine and Biology*, **20**(3), 45-50(2001).



□ CNN(1)

- 波形の正常異常を判定し, 異常波形を抽出
(期外収縮や心房細動など)

□ CNN(2)

- 抽出された異常波形から心房細動を識別

LeNet
ResNet^[1] で比較
SE-ResNet^[2]

[1] K. He, et al., *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*, 770-778(2016).

[2] Jie Hu, et al, "Squeeze-and-Excitation Networks", *2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition*, 7132-7141(2018).

提案手法による心房細動の検出結果

■ テストデータ(未学習)

- ホルター心電図(10名分)
- MIT-BIHデータベース(心電図の公開データベース)

Test Data	CNN(1) & (2)	Accuracy	F1
Holter-ECG	LeNet	89.6%	88.7%
	ResNet	91.3%	90.6%
	SE-ResNet	89.1%	90.4%
MIT-BIH Database	LeNet	79.2%	77.5%
	ResNet	88.0%	88.0%
	SE-ResNet	86.9%	87.3%
Test Data	CNN(2) only	Accuracy	F1
Holter-ECG	ResNet	84.8%	84.4%
MIT-BIH DB	ResNet	87.8%	87.8%

- CNN(2)のみ場合よりも**高い検出精度**
⇒ 規則的なRR間隔をもつ心房細動の検出の可能性
- ResNetを用いた場合に**高い検出精度** (CNN構造の組合せを変えた場合も比較)

想定される用途

- 心房細動の診断補助装置

医師の診断補助, ホルター心電図や集団検診の
心電図からの自動検出, など

想定される業界

- 医療機器メーカー
- 病院・医院などの医療施設
- 福祉施設

など

実用化へ向けた課題

- 心電波形に重畳したノイズによる誤認識が多い
⇒ 前処理の改善が必要
- 被験者によっては検出率が著しく低下することがある
⇒ 検出精度の向上が必要
- 各種パラメータの調整, 学習・試験データの追加

企業への期待

- ハードウェアへの実装と試作
- インターフェース(アプリ)の開発

本技術に関する知的財産権

- 発明の名称 : 心電図からの心房細動
検出方法
- 出願番号 : 特願2021-131365
- 出願人 : 秋田大学
- 発明者 : 田中元志, 鴨澤秀郁

お問い合わせ先

秋田大学 産学連携推進機構
特任准教授 徳原 尊雅

TEL 018-889 - 2712

FAX 018-837 - 5356

e-mail staff@crc.akita-u.ac.jp