

(19) 日本国特許庁(JP)

(12) 公開特許公報(A)

(11) 特許出願公開番号

特開2021-112479

(P2021-112479A)

(43) 公開日 令和3年8月5日(2021.8.5)

(51) Int.Cl.	F I	テーマコード (参考)
A 6 1 B 5/346 (2021.01)	A 6 1 B 5/04 3 1 2 A	4 C 1 2 7
A 6 1 B 5/318 (2021.01)	A 6 1 B 5/04 3 1 0 B	

審査請求 未請求 請求項の数 8 O L (全 15 頁)

(21) 出願番号 特願2020-7778 (P2020-7778)
 (22) 出願日 令和2年1月21日 (2020.1.21)

(71) 出願人 899000068
 学校法人早稲田大学
 東京都新宿区戸塚町1丁目104番地
 (74) 代理人 110002675
 特許業務法人ドライト国際特許事務所
 (72) 発明者 秦 絵里香
 東京都新宿区戸塚町1丁目104番地 学
 校法人早稲田大学内
 (72) 発明者 瀬尾 燦振
 東京都新宿区戸塚町1丁目104番地 学
 校法人早稲田大学内
 (72) 発明者 中山 雅文
 埼玉県戸田市本町1丁目19番3号 戸田
 中央総合病院内

最終頁に続く

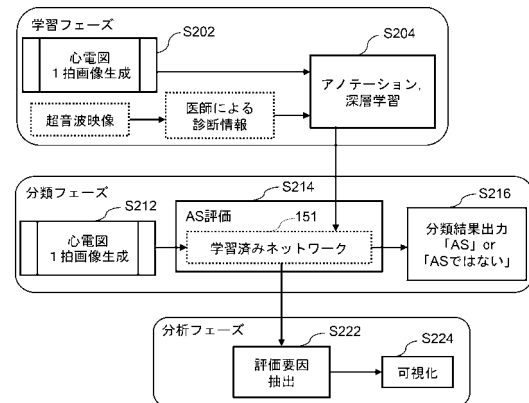
(54) 【発明の名称】 心電信号分析装置及び心電信号分析プログラム

(57) 【要約】

【課題】深層学習を用いて心電図から大動脈弁狭窄症のリスクを識別可能な心電信号分析装置及び心電信号分析プログラムを提供する。

【解決手段】心電信号分析装置は、訓練用の心電信号の心拍間隔が正規化された第1正規化信号（1拍画像）と、訓練用の心電信号に対応する大動脈弁狭窄症に関する医師の診断情報とに基づいて深層学習され、大動脈弁狭窄症のリスクを示す評価結果を出力する学習済みネットワーク151を記憶部に格納しており、入力された心電信号の心拍間隔を、第1正規化信号と同一の間に正規化して第2正規化信号（1拍画像）を生成し（S212）、第2正規化信号を学習済みネットワーク151に入力させ、大動脈弁狭窄症のリスクを示す評価結果を得て（S214）当該評価結果を表示又は印刷する（S216）。

【選択図】図3



【特許請求の範囲】**【請求項 1】**

訓練用の心電信信号の心拍間隔が正規化された第 1 正規化信号と、前記訓練用の心電信信号に対応する大動脈弁狭窄症の診断情報とに基づいて深層学習され、大動脈弁狭窄症のリスクを示す評価結果を出力する学習済みネットワークと、

入力された心電信信号の心拍間隔を、前記第 1 正規化信号と同一の間隔に正規化して第 2 正規化信号を生成する正規化信号生成部と、

前記学習済みネットワークを用いて、前記第 2 正規化信号から、大動脈弁狭窄症のリスクを示す評価結果を得る評価部と、

前記評価部による前記評価結果を出力する出力部と、

を備える心電信信号分析装置。

10

【請求項 2】

前記学習済みネットワークの最終層の信号分布情報を前記評価部での評価要因として抽出する評価要因抽出部を更に備え、

前記出力部は、前記信号分布情報を前記評価結果と対応付けて出力する、請求項 1 に記載の心電信信号分析装置。

【請求項 3】

前記学習済みネットワークは、前記第 1 正規化信号のうち、心電図の S T - T 部を表す範囲に基づいて深層学習されたものである、請求項 1 に記載の心電信信号分析装置。

【請求項 4】

20

前記学習済みネットワークは、前記第 1 正規化信号として、左室肥大の診断に用いられる特定の誘導に対応する信号に基づいて深層学習されたものである、請求項 1 ~ 3 の何れか 1 項に記載の心電信信号分析装置。

【請求項 5】

前記第 1 正規化信号は、前記訓練用の心電信信号を所定のサンプリングレートでアップサンプリングすることで心拍間隔が正規化された信号であり、

前記正規化信号生成部は、前記入力された心電信信号を前記所定のサンプリングレートでアップサンプリングすることで前記第 2 正規化信号を生成する、請求項 1 ~ 4 の何れか 1 項に記載の心電信信号分析装置。

【請求項 6】

30

前記第 1 正規化信号及び前記第 2 正規化信号の各々は、2 次元の画像信号である、請求項 1 ~ 5 の何れか 1 項に記載の心電信信号分析装置。

【請求項 7】

深層学習による学習済みネットワークを用いた心電信信号分析プログラムであって、

前記学習済みネットワークは、訓練用の心電信信号の心拍間隔が正規化された第 1 正規化信号と、前記訓練用の心電信信号に対応する大動脈弁狭窄症の診断情報とに基づいて深層学習され、大動脈弁狭窄症のリスクを示す評価結果を出力するものであり、

前記心電信信号分析プログラムは、

コンピュータに、

心電信信号分析装置に入力された心電信信号の心拍間隔を、前記第 1 正規化信号と同一の間隔に正規化して第 2 正規化信号を生成するステップと、

40

前記学習済みネットワークを用いて、前記第 2 正規化信号から、大動脈弁狭窄症のリスクを示す評価結果を得るステップと、

前記評価結果を出力するステップと、

を実行させるための心電信信号分析プログラム。

【請求項 8】

訓練用の心電信信号から抽出された第 1 の 1 拍心電情報と、前記訓練用の心電信信号に対応する大動脈弁狭窄症の診断情報とに基づいて深層学習され、大動脈弁狭窄症のリスクを示す評価結果を出力する学習済みネットワークと、

入力された心電信信号から第 2 の 1 拍心電情報を抽出する生成部と、

50

前記学習済みネットワークを用いて、前記生成部で抽出された前記第2の1拍心電情報に基づき、大動脈弁狭窄症のリスクを示す評価結果を得る評価部と、

前記評価部による前記評価結果を出力する出力部と、を備え、

前記第1の1拍心電情報は、前記訓練用の心電信信号を500Hzより高い所定のサンプリングレートでサンプリングすることで抽出されるものであり、

前記生成部は、前記入力された心電信信号を500Hzより高い前記所定のサンプリングレートでサンプリングすることで前記第2の1拍心電情報を抽出する、心電信信号分析装置。

【発明の詳細な説明】

10

【技術分野】

【0001】

本発明は、心電図から疾患を判定するための心電信信号分析装置及び心電信信号分析プログラムに関する。

【背景技術】

【0002】

心電図は簡便で侵襲性もないことから循環器疾患の検査として医療機関の規模に関わらず広く行われているものの、その判読には多くの知識と経験が必要である。弁膜症の一つである大動脈弁狭窄症(aortic valvular stenosis: AS)は、心不全や失神、突然死に至ることもある重篤な疾患であるが、熟練した医師であっても心電図のみで診断することは難しく、一般的には確定診断のために心臓超音波検査を必要とする。

20

【0003】

一方で、近年、我が国では地方の医師不足が深刻になっている。医療過疎地域においては専門医がいなかったり、超音波検査を行うことができない場合もあり、重症化しないと都市部の病院へ紹介されないこともある。これらの事情から、心電図によって疾患を自動的に判定するシステムの開発が望まれており、心電図と機械学習又は深層学習とを組み合わせた研究が進んでいる(例えば、特許文献1及び2、非特許文献1参照)。

【先行技術文献】

【特許文献】

【0004】

30

【特許文献1】特表2019-514635号公報

【特許文献2】特表2018-503885号公報

【非特許文献】

【0005】

【非特許文献1】古林せなみ、今井健、石原三四郎、藤生克仁、大江和彦著、「深層学習を用いた心電図波形の正常異常判定に関する研究」、人工知能学会研究会資料、2018年3月15日、vol.5、no.5、p.1-5

【発明の概要】

【発明が解決しようとする課題】

【0006】

40

しかしながら、心電図と機械学習又は深層学習とを組み合わせた従来の研究では、学習機がどのように入力を解釈して結果を判断しているか明らかにしていない。人間の身体は一律ではないため、学習モデルに対して例外のデータが存在する可能性がある。そのような場合であっても、学習機が予測した結果に対して真に妥当なものであるのかを医学的な知見から検証する必要がある。

【0007】

本発明は、上記課題に鑑みてなされたものであり、深層学習を用いて心電図から大動脈弁狭窄症のリスクを適切に識別することが可能な心電信信号分析装置及び心電信信号分析プログラムを提供することを目的とする。

【課題を解決するための手段】

50

【 0 0 0 8 】

本発明の実施形態に係る心電信号分析装置は、訓練用の心電信号の心拍間隔が正規化された第1正規化信号と、訓練用の心電信号に対応する大動脈弁狭窄症の診断情報とに基づいて深層学習され、大動脈弁狭窄症のリスクを示す評価結果を出力する学習済みネットワークと、入力された心電信号の心拍間隔を、第1正規化信号と同一の間隔に正規化して第2正規化信号を生成する正規化信号生成部と、学習済みネットワークを用いて、第2正規化信号から、大動脈弁狭窄症のリスクを示す評価結果を得る評価部と、評価部による評価結果を出力する出力部と、を備える。

【 0 0 0 9 】

本発明の実施形態に係る心電信号分析プログラムは、深層学習による学習済みネットワークを用いた心電信号分析プログラムであって、学習済みネットワークは、訓練用の心電信号の心拍間隔が正規化された第1正規化信号と、訓練用の心電信号に対応する大動脈弁狭窄症の診断情報とに基づいて深層学習され、大動脈弁狭窄症のリスクを示す評価結果を出力するものである。心電信号分析プログラムは、コンピュータに、心電信号分析装置に入力された心電信号の心拍間隔を、第1正規化信号と同一の間隔に正規化して第2正規化信号を生成するステップと、学習済みネットワークを用いて、第2正規化信号から、大動脈弁狭窄症のリスクを示す評価結果を得るステップと、評価結果を出力するステップと、を実行させる。

【 0 0 1 0 】

本発明の実施形態に係る心電信号分析装置は、訓練用の心電信号から抽出された第1の1拍心電情報と、訓練用の心電信号に対応する大動脈弁狭窄症の診断情報とに基づいて深層学習され、大動脈弁狭窄症のリスクを示す評価結果を出力する学習済みネットワークと、入力された心電信号から第2の1拍心電情報を抽出する生成部と、学習済みネットワークを用いて、生成部で抽出された第2の1拍心電情報に基づき、大動脈弁狭窄症のリスクを示す評価結果を得る評価部と、評価部による評価結果を出力する出力部と、を備える。第1の1拍心電情報は、訓練用の心電信号を500Hzより高い所定のサンプリングレートでサンプリングすることで抽出されるものであり、生成部は、入力された心電信号を500Hzより高い所定のサンプリングレートでサンプリングすることで第2の1拍心電情報を抽出する。

【 発明の効果 】

【 0 0 1 1 】

本発明によれば、心拍間隔が正規化された第1正規化信号に基づいて深層学習された学習済みネットワークを用いて、第1正規化信号と同一の心拍間隔に正規化された第2正規化信号から、大動脈弁狭窄症のリスクを示す評価結果を得るようにした。これにより、大動脈弁狭窄症のリスクを適切に識別することが可能となる。

【 図面の簡単な説明 】

【 0 0 1 2 】

【図1】本発明の実施形態に係る心電信号分析装置のハードウェア構成を示すブロック図である。

【図2】12誘導心電図を用いた検査法を説明するための模式図である。

【図3】学習フェーズ、分類フェーズ、及び分析フェーズでの処理を示す模式図である。

【図4】図3の1拍画像生成方法を示すフローである。

【図5】12誘導心電図から得られた1拍画像の波形を示す図である。

【図6】学習済みネットワークによる評価の要因を抽出して特徴領域として可視化する方法を示す模式図である。

【図7】実施例1において、trainデータとtestデータのそれぞれについて分類の精度のEpoch数依存性を示すグラフである。

【図8】Epoch = 180における特徴領域の可視化を示す模式図である。

【図9】特徴領域の位置平均と不偏標本分散を示す模式図である。

【 発明を実施するための形態 】

【 0 0 1 3 】

以下、図面を参照して、深層学習を用いて心電図から大動脈弁狭窄症のリスクを識別する心電信号分析装置及び心電信号分析方法の実施形態について説明する。以下の実施形態では、大動脈弁狭窄症を単に「A S」と呼ぶ。また、以下の説明では、A Sのリスクを示す評価情報が、患者がA Sに罹患しているか否か（A Sの有無）の識別情報であるものとする。

【 0 0 1 4 】

< ハードウェア構成 >

まず、本実施形態に係る心電信号分析方法を実現するシステムの構成について説明する。

10

【 0 0 1 5 】

図 1 に、本実施形態の心電信号分析装置 1 0 0 のハードウェア構成を示す。心電信号分析装置 1 0 0 は、測定部 1 1 と、プロセッサ 1 3 と、記憶部 1 5 と、メインメモリ 1 7 と、出力部 1 9 とを備える。

【 0 0 1 6 】

測定部 1 1 は、患者の体表面上の複数個所に装着した電極から心電図データを得てプロセッサ 1 3 に出力する。本実施形態で扱う心電図データは、Medical waveform Format Encoding Rules (M F E R) に準拠しているものとする。M F E R は、心電図を始め、脳波や呼吸波形など医療波形全般を記述することができるように標準化された規格であり、容易に数値や画像への変換が可能になっている。

20

【 0 0 1 7 】

また、本実施形態では、1 2 誘導心電図を用いた検査法を採用する。1 2 誘導は、図 2 に示すように、6 つの肢誘導 (I 、 I I 、 I I I 、 a V R 、 a V L 、 a V F) と 6 つの胸部誘導 (V ₁ 、 V ₂ 、 V ₃ 、 V ₄ 、 V ₅ 、 V ₆) で構成され、心筋の電氣的活動を 1 2 個のベクトルとして表すものである。測定部 1 1 は、1 2 誘導の心電図データを表す 1 2 種類の心電信号をプロセッサ 1 3 に出力する。なお、1 2 誘導以外の心電図を用いた検査法を採用してもよい。

【 0 0 1 8 】

プロセッサ 1 3 は、Central Processing Unit (C P U) を有し、記憶部 1 5 に格納されたプログラムに従って、各種の処理を実行する。本実施形態において、プロセッサ 1 3 は、測定部 1 1 から入力された心電信号から、心拍間隔が正規化された正規化信号 (1 次元信号列又は 2 次元画像) を生成する正規化信号生成部として機能するとともに、学習済みネットワーク 1 5 1 (後述) を用いて、その正規化信号から A S のリスク (本実施形態では A S の有無) を示す評価結果を得る評価部としても機能する。また、プロセッサ 1 3 は、学習済みネットワーク 1 5 1 の最終層の信号分布情報を、評価部での評価要因として抽出する評価要因抽出部としても機能する。プロセッサ 1 3 によって実行される処理については後述する (図 3 ~ 図 6 参照) 。

30

【 0 0 1 9 】

記憶部 1 5 は、不揮発性メモリであり、プロセッサ 1 3 によって実行される各種のプログラム及びこれらのプログラムの実行時に必要なデータを格納している。本実施形態において、記憶部 1 5 は、プログラムの実行時に必要なデータとして、後述の学習フェーズ (図 3) で構築された学習モデルである学習済みネットワーク 1 5 1 のデータを格納している。

40

【 0 0 2 0 】

メインメモリ 1 7 は、揮発性メモリであり、記憶部 1 5 に格納されたプログラム及びデータは、メインメモリ 1 7 にロードされて実行される。

【 0 0 2 1 】

なお、プロセッサ 1 3 によって実行されるプログラム及びこれらのプログラムの実行時に必要なデータは、心電信号分析装置 1 0 0 に着脱可能で、且つ非一時的なコンピュータ読み取り可能な記録媒体 (例えば、メモリカード) に格納してもよいし、Local Area Net

50

work (L A N)、Wide Area Network (W A N)、インターネット等の通信ネットワークを介して受信するようにしてもよい。

【 0 0 2 2 】

出力部 1 9 は、液晶ディスプレイ (L C D) 等のディスプレイ及び / 又はプリンタを備え、プロセッサ 1 3 での処理結果を表示し、及び / 又は印刷する。

【 0 0 2 3 】

なお、C P U 等の汎用ハードウェアの代わりに、本実施形態の心電信号分析方法の実現に特化した、Application Specific Integrated Circuit (A S I C) 又はField Programmable Gate Array (F P G A) 等の専用ハードウェアを採用してもよい。

【 0 0 2 4 】

また、心電信号分析装置 1 0 0 全体が一体化された据え置き型又は携帯型の心電計として構成されてもよいし、測定部 1 1 を心電計とし、心電計にコンピュータシステム (プロセッサ 1 3、記憶部 1 5、メインメモリ 1 7 及び出力部 1 9) が接続された構成を採用してもよい。

【 0 0 2 5 】

< 学習モデルの構築と心電信号分析方法 >

深層学習を用いて心電図から A S の有無を識別するため、図 3 に示すように、学習フェーズにおいて、深層学習により学習済みネットワーク 1 5 1 (学習モデル) を構築し、分類フェーズにおいて、学習済みネットワーク 1 5 1 を用いて心電図から A S の有無を示す評価結果 (分類結果) を得る。また、分析フェーズにおいて、学習済みネットワーク 1 5 1 による分類の根拠の可視化を行う。

【 0 0 2 6 】

学習フェーズでは、まず、訓練用の心電図データから、患者の心拍の 1 拍に対応する 2 次元波形画像である 1 拍画像 (第 1 正規化信号) が生成される (ステップ S 2 0 2)。ステップ S 2 0 2 及び後述のステップ S 2 1 2 における 1 拍画像の生成方法の詳細は後述する (図 4 及び図 5 参照)。

【 0 0 2 7 】

ステップ S 2 0 2 で生成された 1 拍画像はConvolutional Neural Network (C N N) へ入力され、学習モデルとして学習済みネットワーク 1 5 1 が構築される (ステップ S 2 0 4)。ステップ S 2 0 4 では、各訓練用の心電図に対応する超音波映像に対する専門医による診断情報も含めて学習される (図 3 中の破線部はデータを意味する)。訓練用の心電図に対応する超音波映像から、日本循環器学会ガイドラインに基づき、重症度が中等度以上の A S と診断された患者の心電図を「 A S」、機能的に正常であると診断された患者の心電図を「 A S ではない」として心電図にアノテーションを行い学習する。ネットワーク構造には V G G 1 6 を用いる。V G G 1 6 は、3 × 3 の小さな畳み込みフィルタに 1 6 層の深い C N N 構造を有しているため、高い分類精度の達成を可能にするモデルである。本実施形態では、少ないデータ数であっても汎用的な特徴の抽出を可能にするために、ImageNetの重みを初期値とし、finetuningを行う。なお、深層学習のネットワーク構造は V G G 1 6 に限定されない。

【 0 0 2 8 】

学習フェーズにおける学習済みネットワーク 1 5 1 の構築は、心電信号分析装置 1 0 0 のプロセッサ 1 3 によって行われてもよいし、他のコンピュータによって行われてもよい。構築された学習済みネットワーク 1 5 1 のデータは心電信号分析装置 1 0 0 の記憶部 1 5 に格納される。

【 0 0 2 9 】

分類フェーズでは、未知の心電図データから 1 拍画像 (第 2 正規化信号) が生成される (ステップ S 2 1 2)。ステップ S 2 1 2 で生成された 1 拍画像は、学習済みネットワーク 1 5 1 に入力され、A S の有無を示す評価結果 (分類結果) が得られる (ステップ S 2 1 4)。ステップ S 2 1 4 で得られた分類結果 (「 A S 」 又は 「 A S ではない 」) は、出力部 1 9 のディスプレイに表示され、及び / 又はプリンタに印刷される (ステップ S 2 1

10

20

30

40

50

6)。

【0030】

なお、分類フェーズにおける1拍画像生成(ステップS212)及び/又はAS評価(ステップS214)を、外部コンピュータで実行するようにしてもよい。例えば、インターネット等の通信ネットワークや物理媒体等を経由して心電図データをサーバコンピュータ等の外部コンピュータに送信し、外部コンピュータにおいて、分類フェーズにおける1拍画像生成及びAS評価を実行するようにしてもよい。

【0031】

分析フェーズでは、学習済みネットワーク151にGradient-weighted Class Activation Mapping (Grad-CAM)を適用することによって、ステップS214でのAS評価要因が抽出され(ステップS222)、抽出されたAS評価要因が特徴領域として可視化される(ステップS224)。ステップS224では、出力部19により、ASの有無を示す評価結果が特徴領域と対応付けて表示され、及び/又は印刷される。Grad-CAMを用いたAS評価要因の抽出方法の詳細については後述する(図6参照)。

【0032】

次に、図4及び図5を参照して、1拍画像生成方法(図3のステップS202及びS212)について説明する。

【0033】

まず、入力された心電信号が、Comma Separated Value (CSV)変換された数値データ(CSV信号)として得られる。そして、12誘導のうち、代表してV₅誘導のCSV信号に対し、ベースライン(PQRST波以外の直線部分)を除去するためにウェーブレット変換が行われ(ステップS302)、さらにハード閾値処理が行われる(ステップS304)。その後、ウェーブレット逆変換が行われることにより(ステップS306)、心電図波形の直線部分が省かれ、AS評価に適する心電図の波形的な特徴を抽出しやすいコンパクトな信号とすることができる。次いで、各個人の心拍数データを使用してピーク値(R波)が検出される(ステップS308)。

【0034】

その後、12誘導全てのCSV信号について、時間軸上の1番目のピーク値から2番目のピーク値までの信号が1拍の信号として抽出される(ステップS310)。ここで、心拍の1拍の長さは人によって異なるため、抽出された1拍の信号が所定のサンプリングレートでリサンプリングされる(ステップS312)。ステップS312では、心電図の波形的な特徴を抽出しやすくするため、元の心電信号よりも高いサンプリングレートでリサンプリング(アップサンプリング)される。例えば、測定部11のサンプリングレートが、現在多くの心電計で採用されている500サンプル/秒(500Hz)であれば、500Hzよりも高いサンプリングレート(例えば、1000Hz)でリサンプリングされる。これにより、図5に示すように、心拍間隔が正規化された1拍画像が生成される。図5では、1000Hzでリサンプリングした結果を示している。12誘導の心電信号は、それぞれ正規化によって心拍間隔が揃えられた後、重ね合わされる。また、図5に示すように、1拍画像の電位が-3.0~+3.0[mV]の区間に入るように調整され、心電図波形の名称が併記される。なお、心電図波形によっては、T波の後にU波が出現することもある。

【0035】

学習フェーズにおいて、1拍の長さが異なる心電信号を入力して学習させるのは非常に困難であるが、上述のように心拍間隔が正規化された1拍画像を深層学習の入力に用いることで、少ない入力データで、精密且つスムーズに学習することができる。さらに、分類フェーズにおいても、正規化された1拍画像を学習済みネットワーク151に入力させることで、人によって心拍の1拍の長さが異なっても、妥当な分類結果を得ることが可能となる。また、従来のように超音波検査を行わなくても、ASを診断することが可能となる。また、運用上、上記分類結果は「さらに精密検査を要するか否か」のリスク評価情報として医師に提示するなど、各種用途に用いることも可能である。

10

20

30

40

50

【 0 0 3 6 】

なお、通常の心電計では、医師の診断に適する水準として提供されている心電信信号のサンプリングレートは500Hz(MFER標準)であるのに対し、本実施形態のAS評価向け深層学習に対しては、心電信信号を500Hzよりも高いサンプリングレートでリサンプリングして1拍心電情報を抽出し、抽出された1拍心電情報を供している。これも、上記の学習効果に寄与している。

【 0 0 3 7 】

次に、図6を参照して、Grad-CAMを用いたAS評価要因の抽出方法について説明する。

【 0 0 3 8 】

Grad-CAMは、学習済みネットワークによる分類の根拠を分析するために、畳み込みの最終層の勾配をヒートマップ化することで可視化を図る手法である。これにより、学習済みネットワークへの入力に対する2つのクラスの予測決定の根拠の確認や分析を行うことができ、医師による診断を容易にする。

【 0 0 3 9 】

学習済みネットワーク151にGrad-CAMを適用して得られた画像(CAM情報)を図6のaに示す。本実施形態では、CAM情報における勾配の最大値により各画素の勾配値を除算し、0.5以上の値の画素から構成される領域を特徴領域とする。図6のbにおいて、白画素から構成される領域が特徴領域である。このようにして、AS評価要因を特徴領域として可視化することができる。特徴領域を分析するために、図6のcに示すように、特徴領域の外接長方形を使用し、外接長方形の位置の平均と不偏標本分散を計算する(後述の実施例1参照)。

【 0 0 4 0 】

なお、上述の実施形態では、心電図の2次元画像信号を学習フェーズ、分類フェーズ及び分析フェーズで用いたが、1次元の信号列を用いるようにしてもよい。すなわち、図3のステップS202及びS212では、正規化された1拍画像の代わりに、正規化された1拍信号列を生成し、訓練用の心電図の1拍信号列に基づいて学習済みネットワーク151を構築し、未知の心電図の1拍信号列を学習済みネットワーク151に入力させるようにしてもよい。

【 0 0 4 1 】

なお、上述の実施形態では、ASのリスクを、ASの有無の二値情報として表現していたが、リスクの高低を表現する多段階のランクや数値情報として表してもよい。例えば、学習時に重症度を、高度、中等度、軽度などのASリスクのランクで表してもよいし、これを数値化して表してもよい。

【 0 0 4 2 】

次に、本実施形態の手法に基づく実験と結果について実施例1～実施例4を挙げて説明する。

【 実施例 1 】

【 0 0 4 3 】

実施例1では、所定の期間内に収集された12誘導の心電図データ45, 478件のうち、超音波検査が心電図検査から3カ月以内に行われたデータ3, 513件を実験対象とする。同一患者、ペースメーカーを使用する患者のデータは除外する。「ASではない」データ592件、重症度が中等度以上の「AS」データ108件の中から、前者はランダムに108件、後者は108件全てをデータセットとして使用した。これらのデータを、ニューラルネットワークの重みを更新するtrainデータ、重みの良し悪しを検証するvalidationデータ、学習後に学習モデルの汎化性能を確かめるtestデータの3つに分割する。trainデータは128件、validationデータとtestデータはともに44件とする。学習パラメータを表1に示す。学習時の最適化手法として確率的勾配降下法(SGD)を用いた。

【 0 0 4 4 】

【表 1】

画像サイズ	224×224
Epoch	200
最適化手法	SGD
学習率	0.0001

10

【0045】

ASであるか否かの分類の評価指標には、以下の式(1)～式(4)でそれぞれ定義されるAccuracy、Recall、Precision、F-measure(F値)を用いる。式(1)～式(4)において、TPは正しく「AS」と判断された「AS」データの数、TNは正しく「ASではない」と判断された「ASではない」データの数、FNは誤って「ASではない」と判断された「AS」データの数、FPは誤って「AS」と判断された「ASではない」データの数である。

20

【0046】

【数1】

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

【数2】

30

$$Recall = \frac{TP}{TP + FN} [\%] \quad \cdots (2)$$

【数3】

40

$$Precision = \frac{TP}{TP + FP} [\%] \quad \cdots (3)$$

【数 4】

$$F\text{-measure} = \frac{2\text{Recall} \cdot \text{Precision}}{\text{Recall} + \text{Precision}} [\%] \quad \cdots (4)$$

【0047】

図7に、trainデータとtestデータのそれぞれについてAccuracy（分類の精度）のEpoch数依存性を示す。図7のAccuracy曲線に示すように、最も高いAccuracyを示したのはEpoch = 101のときである。このときの分類結果の各評価基準値を表2に示す。Precision = 0.842であることから、疾患があるデータを、疾患がある、と比較的高精度で分類することができたことがわかる。

10

【0048】

【表2】

Accuracy	0.795
Recall	0.727
Precision	0.842
F-measure	0.780

20

【0049】

30

図7より、testデータのAccuracyは、Epoch = 50付近から概ね一定の値である。従って、Accuracyのみで学習モデルの性能を判断するのは妥当ではないと考えられるため、異なるEpochの値について、予測決定箇所の変位を確認することとした。そこで、Epoch = 20、100、180について、Grad-CAMによる特徴領域の可視化を行った。すると、Epoch = 180では、図8に示すように、リサンプリングした1拍の信号[0、1000]のうち、早い時間帯の領域（以下、領域Aという。）を判定基準としていることが判明した。さらに、Epoch = 20、100においても、領域Aを特徴領域と認識したデータが存在した。そこで、testデータ44件のうち、領域Aを特徴領域として認識した数が最も多いEpochを探ることとした。その結果、表3に示すように、領域Aを特徴領域として示したデータ数が多かったのは、学習の終盤であるEpoch = 180のときであった。これは、学習の進行によって詳細に特徴領域を捉えるようになってきていることを示している。

40

【0050】

【表 3】

Epoch	AS (データ数)	ASではない (データ数)
20	5	7
100	4	13
180	4	16

10

【0051】

大動脈弁狭窄症（AS）とは、全身に血液を送り出す心臓の左心室の出口（大動脈弁）が狭い状態のことである。弁が狭いことによって、左心室は正常の状態よりも強い力で血液を送り出すことが必要になるため、左心室が慢性的に負荷を受け、壁が厚くなる（左室肥大）病態を併発する。心電図から左室肥大を判断する基準はいくつかあるが、AS以外でも左室肥大の原因もあることから、左室肥大の所見だけ診断することは困難である。また、心臓弁膜症疾患は、重症化してからはじめて症状が出る場合も多いが、重症のAS患者は突然死も起き得ることから、重症度が中等度以下の段階で診断することが望ましい。そこで、Grad-CAMを用いて抽出された特徴領域と、これらの症状との関連性を検討する。

20

【0052】

表3に示すように、Epoch = 180のときに領域Aを特徴領域として認識したデータ数が最も多かったことから、このときの結果をさらに解析する。図9に、「AS」と「ASではない」のそれぞれについて、特徴領域の外接長方形の位置平均及び不偏標本分散を算出した結果を示す。図9において、実線が位置平均を表し、点線が不偏標本分散を表す。

【0053】

領域Aでは、位置平均、不偏標本分散を考慮した場合にも、「AS」と「ASではない」のそれぞれで注目している時間域、電位はほとんど変わらないことから、領域Aは心電図におけるST-T部付近を示していると考えられる。ここで、ST-T部とは、図5に示すQRS波の終わりからT波までを指す。QRS波とはQ波の始めからS波の終わりまでの部分を指す。ASの場合、心電図には左室肥大の兆候が見られるが、具体的な特徴として、QRS波の高電圧、右下がりのST低下、陰性T波が挙げられる。QRS波は、心室の興奮を表す。STとは、QRS波の終わりからT波の始まりまでを指す。ST低下とは、心電図のベースラインよりも低い状態である。T波とは、ST部分に続いて見られる波形であり、陰性T波とはT波が陰性電位の状態である。よって、領域Aが特徴領域と認識されたのは、これらST低下及び陰性T波に注目していたと考えられる。

30

【0054】

上述の実施形態では、心電図を用いてASを識別する学習モデルを構築するために、心拍間隔が正規化された1拍画像を入力とする手法を採用した。その結果、実施例1では、表2に示すように、最大79.5[%]の精度で識別可能であることがわかった。また、Grad-CAMを用いることにより、ST-T部付近の領域に基づいてASを識別していることがわかった。この領域が医師の判断基準と類似していることから、構築された学習モデルが、妥当な判定をしていると考えられる。

40

【実施例2】

【0055】

実施例2では、実施例1と同一の患者の心電図データを用い、1拍画像のうち特徴領域を入力とした深層学習を行った実験について説明する。具体的には、図9の外接長方形の

50

平均位置に基づき、1 拍の信号 [0、1 0 0 0] のうち、領域 A に対応する [2 0 0、4 0 0] のみに絞り、電位幅も - 3 . 0 ~ + 3 . 0 [m V] から - 1 . 0 ~ + 1 . 0 [m V] に変更した心電信号を入力として上述の深層学習 (ステップ S 2 0 4) を行った。学習パラメータは、実施例 1 の表 1 と同一である。

【 0 0 5 6 】

実施例 2 の実験によると、Epoch 数の増加に伴って、train データの Accuracy 曲線は 1 へ収束し、test データの Accuracy 曲線は 0 . 8 前後を推移していた。test データの Accuracy は、Epoch = 1 1 4 のときに最大値 0 . 8 1 8 となった。また、学習モデルの全体的な性能を表す F-measure が 0 . 8 を上回ったことから、入力が 1 拍の信号のときよりも特徴領域に絞った方が、学習モデルの性能が向上したと言える。

10

【 実施例 3 】

【 0 0 5 7 】

実施例 1 及び実施例 2 の実験では、1 2 誘導の心電図データを用いたときの学習モデルの評価を行った。これらの実験結果より、構築された学習モデルが、医師が左室肥大と診断したときの基準に類似していることがわかった。そこで、実施例 3 では、1 2 誘導のうち、左室の電位を読み出すことができる 4 誘導 (I、a V L、V₅、V₆) に着目し、4 誘導の心電図データの 1 拍画像を入力とした学習モデルの評価を行った。実施例 3 においても、図 4 で示した方法と同様の方法を用い、サンプリングレート 1 0 0 0 H z でリサンプリングすることで 1 拍画像を生成した。学習パラメータは、実施例 1 の表 1 と同一である。

20

【 0 0 5 8 】

実施例 3 の実験によると、Epoch 数の増加に伴って、train データの Accuracy 曲線は 1 へ収束し、test データの Accuracy 曲線は 0 . 7 ~ 0 . 8 を推移するが、学習の終盤でわずかに減少することがわかった。test データに対して最も高い精度が得られた Epoch 数は複数個あるが、Epoch = 1 2 8 のときを代表として分析した結果、Accuracy = 0 . 7 7 3 であった。1 2 誘導の心電図の 1 拍画像を入力とした実施例 1 では、Accuracy の最大値が 0 . 7 9 5 であることから、4 誘導の 1 拍画像を入力とした場合は、1 2 誘導の 1 拍画像を入力とした場合よりもわずかに分類の精度は下がるが、ほぼ同じであることがわかった。

【 実施例 4 】

【 0 0 5 9 】

実施例 4 では、実施例 3 において生成された 4 誘導の心電図の 1 拍画像のうち、特徴領域と判断された領域の信号を入力として深層学習を行った実験について説明する。具体的には、実施例 2 と同様に、1 0 0 0 H z でリサンプリングして得られた 1 拍の信号 [0、1 0 0 0] のうち [2 0 0、4 0 0] の範囲内で、且つ電位幅が - 1 . 0 ~ + 1 . 0 [m V] の画像を入力として深層学習を行った。学習パラメータは、実施例 1 の表 1 と同一である。実施例 4 の実験によると、test データの Accuracy は、全体的に実施例 3 よりも高く、特に、Epoch = 1 4 1 のとき Accuracy = 0 . 8 8 6 の最大値をとった。また、Recall、Precision、及び F-measure についても、実施例 1 ~ 実施例 3 よりも高い値を示した。

30

【 0 0 6 0 】

表 4 に、実施例 1 ~ 実施例 4 の Accuracy の最大値の比較結果を示す。実施例 1 と実施例 2 とを比較した結果、及び実施例 3 と実施例 4 とを比較した結果より、1 拍画像よりも特徴領域に絞って深層学習をした方が、分類の精度が向上することがわかった。また、1 拍画像を入力とする実施例 1 と実施例 3 とを比較すると、4 誘導に限定することで若干精度が下がるが、特徴領域を入力とする実施例 2 と実施例 4 とを比較すると、4 誘導に限定することで飛躍的に精度が向上した。すなわち、医師が左室肥大の診断に用いる特定の 4 誘導に限定し、且つ特徴領域を入力とした深層学習をすることで、不要なデータが省かれ、効果的に学習モデルを構築することができる。

40

【 0 0 6 1 】

【表 4】

実施例	実施例 1	実施例 2	実施例 3	実施例 4
誘導数	12		4	
誘導	I, II, III, aVR, aVL, aVF, V ₁ , V ₂ , V ₃ , V ₄ , V ₅ , V ₆		I, aVL, V ₅ , V ₆	
領域	[0, 1000]	[200, 400]	[0, 1000]	[200, 400]
Accuracy 最大値	0.795	0.818	0.773	0.886

10

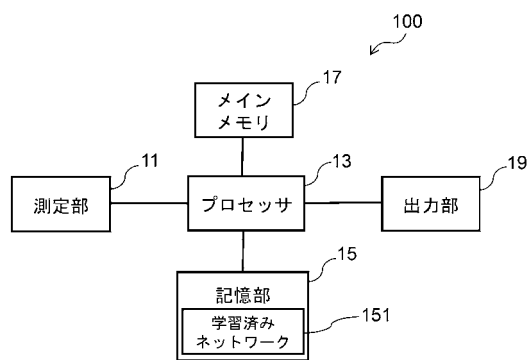
【符号の説明】

【 0 0 6 2 】


- 1 1 測定部
- 1 3 プロセッサ
- 1 5 記憶部
- 1 5 1 学習済みネットワーク
- 1 7 メインメモリ
- 1 9 出力部
- 1 0 0 心電信号分析装置

20

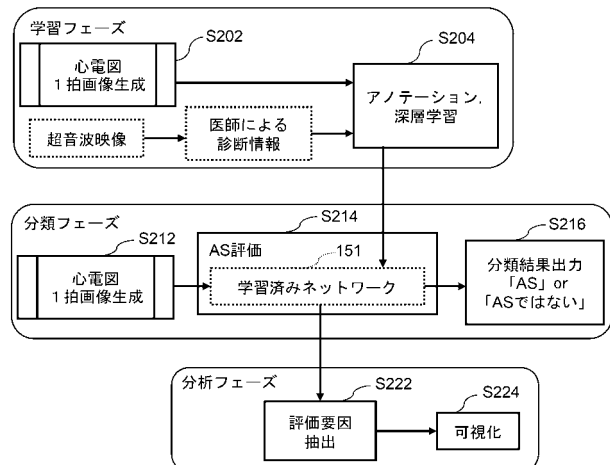
【図 1】



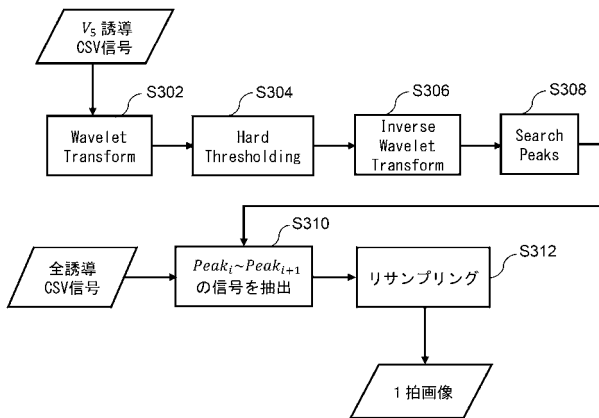
【図 2】




【図 3】




【図 4】




【図 5】




【図 6】




【図 7】



【図 8】



【図 9】



フロントページの続き

(72)発明者 岩 崎 清隆

東京都新宿区戸塚町 1 丁目 1 0 4 番地 学校法人早稲田大学内

(72)発明者 大谷 淳

東京都新宿区戸塚町 1 丁目 1 0 4 番地 学校法人早稲田大学内

F ターム(参考) 4C127 AA02 FF01 GG02 GG05 GG10 GG13 GG16