

超短時間心拍変動解析によるウェアラブル心房細動重症度診断クラウド AI の開発

代表研究者 藤 原 幸 一 名古屋大学大学院工学研究科・准教授
共同研究者 川 治 徹 真 三菱京都病院循環器内科

1 緒言

心房細動（AF）は、心房の無秩序かつ機能不全な収縮による不規則かつ高速な心拍を特徴とする進行性心血管疾患である【1】【2】。この疾患は、脳卒中や心不全などの重篤な心血管合併症を引き起こす。AF のリスクは加齢とともに増加し、現在、最も一般的な不整脈の一つとなっている。世界における AF 患者の年齢分布は、49 歳以下（8.5%）、50～79 歳（62%）、80 歳以上（29.5%）であり、男女比は 46.8 対 53.2 である【3】。日本人においても、これらの比率はほぼ同様である【4】。また、人口の高齢化に伴い、AF 患者数は今後大幅に増加し、2050 年までに米国で 600 万～1600 万人、アジアでは 7200 万人に達すると予測されている【5】。

AF 患者は動悸を自覚する場合もあるが、無症候性の場合もあり、無症候性であっても合併症を引き起こすリスクがある。発見が遅れた場合、予後不良となることがある【6】【7】。トリガの隔離を目的としたカテテルアブレーションは、特に早期段階の AF 患者において AF の負荷を軽減する効果がある。したがって、動悸や AF に伴う合併症を有する患者に対して、非侵襲的な AF スクリーニングシステムの開発が推奨される。

臨床現場では、12 誘導心電図（ECG）における細動波および不規則な心室応答に基づき AF が診断される。聴診や触診で拍動の不規則性が疑われた場合、AF を疑う。しかし、短時間の ECG 検査では、測定中に AF が発生しない場合、AF を見逃すことがある。長時間の心電図モニタリングにはホルター心電図が用いられるが、移動制限や貼付部位のかゆみなど患者に負担が大きく、結果も病院でしか解析できず、リアルタイム評価が難しい。そのため、家庭でも簡便に使用できる AF スクリーニング手法が望まれている。

30 秒以上持続する短時間の AF 発作も、臨床的に有意な AF と見なされる。短時間の AF や頻発する心房期外収縮は、未検出の AF リスクを高める【8】。未検出の AF をスクリーニングする観点から、発見された不整脈の重症度を「正常」、「軽度異常（頻発期外収縮）」、「重度異常（AF）」の 3 段階に分類すべきである。

R-R 間隔（RRI）は、ECG 上の R 波から次の R 波までの間隔であり、AF スクリーニングに利用できる。R 波は ECG 波形の中で最も高いピークであるため、アーチファクトがあっても比較的検出しやすい。ウェアラブルデバイスを用いて簡便かつ正確に RRI を計測する技術が開発されており【9】、家庭での簡易 AF スクリーニングが期待できる。しかし、従来は AF の有無の 2 値分類に留まっており、実臨床での利用は難しい。

本研究では、IoT 技術に基づき、ウェアラブル心臓デバイス、スマートフォンアプリ、クラウドサーバーを構成要素とする新たな AF スクリーニングシステムを開発した。開発中のシステムは、機械学習（ML）ベースの RRI 分類モデルにより、30 拍の RRI 記録（約 30 秒の記録）を「正常」、「軽度異常」、「重度異常」の 3 段階に分類する。この分類は、臨床現場に適合している。IoT 技術を活用することで、家庭用 AF スクリーニングシステムの実現が期待され、AF の早期診断・介入に貢献できる可能性がある。

さらに、臨床利用への第一歩として、100 名の AF 疑い患者から収集した 200 レコードを用いて前向き研究を実施し、本システムの精度を検証した。加えて、Apple Watch の AF 検出機能との比較も行った。

2 関連研究

心房細動（AF）検出の負担を軽減するため、さまざまな機械学習（ML）モデルが開発されてきた【10】【11】。これらの多くは、12 誘導心電図（ECG）波形を解析対象としている。たとえば、Du らによるモデルでは、単一誘導の ECG トレースを用いて正常状態と AF を区別する際、約 94%の感度を達成した【10】。また、Langley らのモデルでは、単一誘導 ECG トレースから不整リズムを検出する感度が 90.5～95.2%であった【12】。さらに、Hannun らは、畳み込みニューラルネットワーク（CNN）に基づく ML モデルを開発し、12 誘導 ECG 記録を 12 種類のリズムに分類することに成功した【13】。Fan らは、多スケール融合 CNN（MS-CNN）を用いて高精度（96.99～98.13%）で AF を検出するアルゴリズムを開発した【11】。これらの研究は、ニューラルネットワーク（NN）ベースの ML モデルが、ほぼ心臓専門医と同等の性能を達成できることを示す。

12 誘導 ECG 記録に加え、単一誘導 QRS 複合波も ML 技術により不整リズム検出に使用可能である【14】【15】。単一誘導 ECG 記録を用いて細動と粗動を自動セグメントするアルゴリズムも提案されている【16】。また、Dupulthys らは、単一誘導 ECG に基づく ML モデルが、追加的に AF リスクに関する臨床情報を同時に使用することで、12 誘導 ECG とほぼ同等の AF 検出性能に達したことを報告した【17】。

単一誘導デバイスは、12 誘導デバイスよりも操作が容易であるが、正確な QRS 複合波の記録には、ECG 電極の正確な装着など、慎重な注意が依然として必要である。また、身体動作によるアーチファクトにより、ECG 波形が影響を受ける場合もある。これらの手法では、ベースラインドリフトやアーチファクトのない高品質な ECG 波形が求められる。高品質な ECG 測定は、皮下に埋め込むインサータブル心臓モニター（ICM）により実現でき、これに基づく AF 検出アルゴリズムも開発されている【18】【19】。しかし、ICM 使用には植え込み手術が必要であり、患者負担が大きい。

ECG 波形に代わるものとして、RRI データに基づく AF スクリーニング手法も提案されている。RRI データはウェアラブルセンサーにより容易に計測可能であるためである【9】。たとえば、Saiful らは、近傍コンポーネント解析（NCA）を用いて RRI 記録から高精度に AF をスクリーニングする方法を開発した【20】。また、Petrucchi らも RRI 分布に基づくアルゴリズムを開発している【21】。ただし、これらの研究は、AF の有無のみを診断する二値分類にとどまっており、临床上求められる多段階分類には対応していない。

近年、スマートウォッチは心機能を簡便かつ非侵襲的にモニタリングできるデバイスとして注目されている。中には、光電式容積脈波記録（PPG）センサーを搭載したものもあり【22】、PPG 記録から AF を検出するアプリも開発されている。米国では、Perez らによって大規模なスマートウォッチによる AF 検出の評価が行われたが、アプリから不規則な脈拍の通知を受けた参加者のうち、実際に病院で AF が確認されたのは 34%にとどまった【23】。また、Wasserlauf らは、Apple Watch の PPG センサーによる AF 検出性能を多施設共同研究で検証し、感度 72%を報告している【24】。Lubitz らによる Fitbit における AF 検出機能の調査では、感度 67.6%と報告されている【25】。これらの研究は、PPG 測定スマートウォッチが正確な AF スクリーニングには十分でないことを示唆している。

さらに、単一誘導 ECG 測定が可能なスマートウォッチも市販化されている【26】。たとえば、Apple Watch は単一誘導 ECG 記録に基づく不整リズム検出機能を備えており、米国 FDA の承認も取得している。Basel Study では、市販の単一誘導 ECG 測定可能な 5 種のデバイスに対する AF 検出性能が評価され、感度 58～85%、特異度 69～75%という結果が得られた【27】。このように、スマートウォッチは ECG 測定を手軽に行える利点がある一方で、動作アーチファクトに弱く、精度向上が臨床利用には依然として必要である。また、スマートウォッチは使用者が積極的にデバイスのクラウン部分に指を触れて計測を開始する必要があるため、AF 発作を見逃す可能性もある。そのため、家庭用 AF スクリーニングには、別のモダリティを採用することが望ましい。

3 システム構成

3-1 概要

開発中の IoT ベース AF スクリーニングシステムは、AF 疑い患者の 30 拍分の RRI 記録を、正常、軽度異常（頻発期外収縮）、重度異常（AF）の 3 段階のいずれかに分類する。本システムは、機械学習技術を用いて構築された RRI 分類モデルを利用する。図 1 にシステムの概要図を示す。図 1 に示すように、本システムは以下の 7 ステップから構成される。




図 1：システム概要

1. AF 疑い患者が装着するウェアラブル心臓センサーで RRI を測定する。
2. 測定された RRI を、R 波が検出されるたびに Bluetooth Low Energy（BLE）を介してスマートフォンアプリへ送信する。
3. アプリ内に 30 拍分の RRI を蓄積する。
4. アプリからインターネット経由で 30 拍分の RRI 記録をクラウドにアップロードする。
5. クラウドに実装された RRI 分類モデルにより、アップロードされた RRI 記録の AF 重症度を分類する。
6. 推定された重症度をアプリに送信する。

7. アプリを通じて患者に AF 重症度を通知する。

なお、開発中の本システムでは、プライバシー保護に配慮し、年齢、性別、既往歴、職業、居住地域など、患者の個人情報はクラウドへ送信されない設計となっている。

3-2 アプリおよびクラウド

学習済みの RRI 分類モデルを、スマートフォンアプリおよびクラウドサーバーに実装した。スマートフォンアプリは、AF 疑い患者の 30 拍分の RRI 記録を受信し、それをクラウドに送信する。図 2 に開発中のアプリのスクリーンショットを示す。クラウド側では、以下の手順により解析を行う。




図 2：開発中のアプリ

1. アプリからインターネット経由で 30 拍分の RRI 記録を受信する。
2. 受信した 30 拍 RRI 記録から心拍変動（HRV）特徴量を抽出する。
3. 抽出した HRV 特徴量を RRI 分類モデルにより 3 段階の重症度に分類する。
4. 分類結果をインターネット経由でアプリに送信する。

クラウド実装には AWS Lambda を利用した。AWS Lambda はサーバレス・イベント駆動型のコンピューティングサービスであり、データ処理要求が発生したときのみプログラムを実行する。このため、クラウドのランニングコスト削減に寄与する。本システムでは、30 拍分の RRI 記録の受信がイベントトリガーとなり、Lambda 上で自動的に処理が開始される。

3-3 ウェアラブルセンサ

本 AF スクリーニングシステムでは、患者の RRI 記録を測定するためにウェアラブルセンサーを使用する。本研究では、山川らによって開発されたウェアラブルセンサーを採用した【9】。このセンサーは、使い捨て電極を用いて標準 II 誘導で毎秒 1kHz の心電図波形を測定し、測定された ECG から自動的に R 波を検出、RRI を計算し、BLE のハートレートプロファイル経由でスマートフォンなどのデバイスに送信する機能を持つ。図 2 に本研究で使用したデバイスを示す。本研究では山川らが開発したセンサを用いたが、心電図波形を 200Hz 以上のサンプリングレートで測定でき、かつ BLE ハートレートプロファイルで RRI データを自動計算・送信できる他のデバイスも本システムに利用可能である。心拍変動（HRV）解析のガイドラインによれば、正確な解析には少なくとも 200Hz での ECG 記録が必要とされている【28】。

4 機械学習モデル

4-1 心拍変動（HRV）解析

RRI 分類モデルは機械学習（ML）技術に基づいて構築されており、モデル構築のためには適切な入力特徴量の選定が重要である。本研究では、RRI 分類モデルの入力として複数の心拍変動（HRV）特徴量を採用した。

心拍変動（HRV）は、RRI の揺らぎを意味し、自律神経系（ANS）の活動を反映する生理現象である。自律神経系は、心拍、体温、呼吸、発汗などの身体活動を無意識下で制御しており、さまざまな疾患や障害と関連している。HRV 解析は、てんかん、睡眠障害、熱中症、認知症など、多様な健康モニタリングおよび疾患スクリーニングに応用されてきた【29】～【35】。また、HRV と AF との関連も多数報告されている【36】【37】。したがって、HRV 解析により AF 検出が可能であると考えられる。

HRV 解析の臨床ガイドラインでは、少なくとも 2 分以上の RRI 記録を用いることが推奨されているが【28】、本研究では約 30 秒間の 30 拍 RRI サンプルから HRV 特徴量を抽出した。1 分未満の RRI データを用いる超短期 HRV（UST-HRV）解析手法が提案されており、既存の研究によりその妥当性が確認されている【38】～【40】。本研究では、HRV 解析の臨床ガイドライン【28】に従い、以下の 17 種類の HRV 特徴量を RRI 分類モデルの入力とした。

- **時間領域特徴量**：RRI 平均（meanNN）、標準偏差（SDNN）、隣接する RRI 間の標準偏差（SDSD）、隣接する RRI の差の平方平均平方根（RMSSD）、50ms 以上差がある隣接 RRI の数（NN50）、全 RRI に対する NN50 の比率（pNN50）、心拍数平均（meanHR）、トータルパワー（Total Power, TP）。
- **周波数領域特徴量**：低周波数帯域（0.04～0.15Hz）のパワー（LF）、高周波数帯域（0.15～0.4Hz）のパワー（HF）、LF/HF、正規化 LF の単位（LFnu）、正規化 HF（HFnu）。

- 非線形特徴量：ポアンカレプロットにおける長軸方向の標準偏差（SD1）、短軸方向の標準偏差（SD2）、SD1/SD2【41】。

4-2 不均衡データ解析

一般的な分類アルゴリズムでは、各クラスのサンプル数がバランスしていることが望ましい。しかし、本研究で取り扱うデータでは、正常、軽度異常、重度異常の RRI 記録数に大きな偏りが存在する。すなわち、正常 RRI 記録が圧倒的に多く、軽度異常・重度異常の記録は少数である。これは、日常臨床における動悸症状患者の中で不整脈発生率が低いためである。

例えば、99 個の正常サンプルと 1 個の異常サンプルを持つデータセットでは、すべてを正常と分類しても 99%の精度を達成できる。しかし、これは実際には異常検出に失敗しており、適切な分類とはいえない。このような状況は「不均衡データ問題」と呼ばれる【42】。医療データ解析では、対象疾患を有する患者数が健康な人に比べて少ない場合が多く、しばしばこの問題に直面する。そのため、不均衡データに対応可能な学習フレームワークが必要である。

アンサンブル学習は、複数の弱い分類器を統合して強い分類器を構築する手法であり【43】、不均衡データに対しても比較的良好な性能を発揮する。特に、ブースティングは、前回の分類器の誤分類情報を利用して次の分類器を構築する手法であり【44】、最終的な出力は複数分類器の重み付き投票によって決定される。さらに、不均衡なサンプル数を補正するサンプリング手法も存在する。ランダムアンダーサンプリング（RUS）は、多数派クラスのサンプルをランダムに除去することでクラス数を均等化する【45】。これらのサンプリング手法は、アンサンブル学習と組み合わせることができる。RUSBoost は、RUS とブースティングを組み合わせた代表的な手法である【46】。

4-3 モデルの学習

本研究では、以下に示す手順に従って RRI 分類モデルの学習を行った。

1. 患者から 30 拍分の RRI 記録と、重症度ラベル（0：正常、1：軽度異常、2：重度異常）を収集する。
2. RRI データから 17 種類の HRV 特徴量を抽出し、特徴行列を作成する。
3. すべての患者の特徴行列とラベルを統合する。
4. ランダムに正常サンプルを削除することでクラス間のデータ数を均衡化する。
5. 特徴量を平均 0、分散 1 に標準化する。
6. 標準化後のデータを用いて、RUSBoost により RRI 分類モデルを学習する。

学習アルゴリズムとして、勾配ブースティング決定木（GBDT）である XGBoost を採用した【47】。

学習された RRI 分類モデルは、入力された RRI データに基づき、その重症度を「正常（0）」「軽度異常（1）」「重度異常（2）」のいずれかに分類する。

4-3 性能評価指標

本研究では、三値分類を対象とするため、混同行列を中心とした性能評価を行った。加えて、以下の指標を使用した。

- 精度（Accuracy）：正しく分類されたサンプル数／全サンプル数
- 感度（Sensitivity）：正しく異常と分類された異常サンプル数／異常サンプル数
- 偽陰性率（FNR）：異常サンプルが正常と誤分類された率
- 見落とし率（Overlooking rate）：重度異常サンプルが正常と誤分類された率

また、正常および軽度異常を「非 AF」、重度異常を「AF」とみなした二値分類として ROC 曲線および AUC も算出した。なお、Apple Watch は二値分類（AF/非 AF）のみを行うため、Apple Watch との比較では感度、特異度、精度を用いた。

5 システム前向き評価

5-1 評価手順

本システムの前向き評価を実施するため、2023 年 2 月から 2023 年 8 月にかけて、京都大学病院および三菱京都病院において AF が疑われる患者を対象に 12 誘導心電図検査を実施した。なお、心血管植込み型電子デバイス（CIEDs）を装着している患者は除外対象とした。本研究は、京都大学病院倫理審査委員会の承認を受け、すべての参加者から書面によるインフォームドコンセントを取得した。

臨床診療に則り、参加者の 12 誘導心電図データをもとに循環器専門医が診断を行い、以下 3 群に分類した：ほぼ正常（期外収縮 5%未満）、頻発期外収縮あり（追跡管理が必要、30 秒未満の AF または期外収縮 5%以上、AF（30 秒以上持続し、治療対象）。

なお、通常の 12 誘導心電図検査は短時間であるため、診断時に不整脈を示さない場合でも、実際には期外収縮を伴う可能性があることに留意が必要である。

12 誘導心電図検査中、参加者には本システムのウェアラブル心臓センサーを装着してもらい、AF スクリーニングシステムの評価を行った。記録は各参加者について 2 回実施し、1 回目と 2 回目の間隔は 24 時間以上空けることとした。さらに、対象患者がカテーテルアブレーションを受ける場合、施術前後に記録を行い、アブレーション施術の影響を調査した。12 誘導心電図検査には ECG-2550（日本光電製）を用い、スマートフォンには Xperia 5 II（Sony 製）を使用した。

比較対象として、Apple Watch Series 8（A2771、Apple 社製）を装着し、単一誘導 ECG 機能による AF 検出結果も収集した。Apple Watch は FDA による 510(k) 認可を受けた医療機器（SaMD）であり、被験者にはクラウン部分に指を触れ約 30 秒間記録するよう指示した。記録後、Apple Watch は「AF 検出」または「AF 非検出」の二択で結果を表示した。

統計解析には、 t 検定を用いて参加者の背景に関する群間比較を行い、マクネマー検定を用いて AF 検出性能の比較を行った。有意水準は 5%に設定した。

5-2 研究参加者

AF 疑い患者 100 名から RRI データを計 200 レコード収集した。参加者の平均年齢は 70.7 ± 11.4 歳であり、男性は 66 名（66.0%）であった。前向き評価と後向き評価において、参加者の年齢・性別に有意差がないことを確認した（ $p > 0.05$ ）。収集された 12 誘導心電図レコードの分類内訳は、ほぼ正常 32.5%、頻発期外収縮 23.0%、明確な AF 39.5%であった。

なお、100 名のうち 87 名は、初回記録後にカテーテルアブレーション施術を受けたことを確認した。これは、短期間の 12 誘導心電図検査では洞調律と診断されても、発作性 AF 患者に対する早期治療（発作性から持続性への進展防止）が推奨されるためである。

5-3 性能評価

200 レコード中、参加者 A（女性 64 歳）、B（男性 78 歳）、C（男性 73 歳）の 3 件（1.5%）は「判定不能」とされた。このため、評価対象は 197 件となった。本システムの性能は以下の通りであった。

- 精度（Accuracy）：88.8%
- 感度（Sensitivity）：95.1%
- 偽陰性率（FNR）：4.92%
- 見落とし率（Overlooking rate）：2.63%

図 3（左）に本システムの混同行列を示す。混同行列横の表には、各正解クラスにおける正解率と誤分類率が示されている。これらの結果は、後向き評価で得られた RRI 分類モデルの性能と比較して、本システムが前向き評価においても性能低下しないことを示している。

5-4 Apple Watch との比較

Apple Watch は、「AF 検出」または「非 AF」の 2 値分類を行うため、本評価ではほぼ正常および頻発期外収縮を「非 AF」、明確な AF を「AF」と定義した。Apple Watch では、17 件（8.5%）の記録が「判定不能」とされ、対象外となった。さらに、心拍数（HR）が 120bpm 以上または 50bpm 以下であった患者から 7 件（3.5%）




図3：開発中システム（左）と Apple Watch（右）の AF 診断性能

の記録も除外した。これは、これらの HR 範囲では Apple Watch による AF 検出機能が働かない可能性があるためである【48】。最終的に 176 件が比較対象となった。Apple Watch の AF 検出性能は以下の通りであった。

- 精度 (Accuracy) : 92.6%
- 感度 (Sensitivity) : 88.7%
- 特異度 (Specificity) : 95.2%

図3（右）に Apple Watch の混同行列を示す。

なお、Apple Watch では、前述の参加者 A、B、C に対して AF を正しく検出できた。一方で、判定不能となった記録数は本システムよりも多かった。比較のため、評価手順を統一し、以下の基準でシステムと Apple Watch の性能を比較した。ここでは「正常」および「軽度異常」を「非 AF」とみなし、「重度異常」を「AF」とみなした。また、どちらか一方で「判定不能」となった記録、および Apple Watch で心拍数 120bpm 以上または 50bpm 以下の記録は除外した。これにより、最終的な比較対象は 94 名の患者から得られた 173 レコードとなった。この比較条件における性能は以下の通りである。

指標	本システム	Apple Watch
精度 (Accuracy)	94.2%	92.5%
感度 (Sensitivity)	89.7%	88.2%
特異度 (Specificity)	97.1%	95.2%

なお、マクネマー検定の結果、本システムと Apple Watch の間に有意差は認められなかった ($p=0.42$)。

6 結言

本研究では、30 拍分の RRI 記録から心房細動 (AF) をスクリーニングできる IoT ベースのシステムを開発した。本システムは、ウェアラブル心臓センサー、スマートフォンアプリ、クラウド上の機械学習 (ML) モデルで構成される。本システムは、30 拍分の RRI 記録を「正常」「軽度異常 (頻発期外収縮)」「重度異常 (AF)」の三段階に分類することができる。機械学習モデルには XGBoost を採用し、心拍変動 (HRV) 解析により抽出された 17 種類の特徴量を用いた。

AF 疑い患者 100 名 (計 200 レコード) を対象とした前向き試験にて、精度 88.8%、感度 95.1%、偽陰性率 4.92%、見落とし率 2.63% という良好な結果が得られた。比較対象とした Apple Watch の AF 検出機能に対しても、統計的に有意な差は認められず ($p=0.42$)、開発中の本システムが家庭や通常診療における AF スクリーニングに十分適用可能であることが示された。

本システムは、短時間 (約 30 秒) の簡便な計測により、高精度に AF スクリーニングが可能であり、早期診断・早期治療に寄与できると考えられる。さらに、クラウド実装により、モデルのリアルタイム更新や大規模データ解析も可能である。

今後は、さらに大規模な臨床試験を通じて実臨床応用に向けた検証を進めるとともに、セキュリティ強化を含む社会実装に向けた課題にも取り組む予定である。

【参考文献】

1. Gerhard Hindricks, et al. 2020 ESC Guidelines for the diagnosis and management of atrial fibrillation developed in collaboration with the European Association for Cardio-Thoracic Surgery (EACTS): The Task Force for the diagnosis and management of atrial fibrillation of the European Society of Cardiology (ESC). *Eur Heart J*, Vol. 42, No. 5, pp. 373–498, 2021.
2. Craig T January, et al. 2019 AHA/ACC/HRS Focused Update of the 2014 AHA/ACC/HRS Guideline for the Management of Patients With Atrial Fibrillation: A Report of the American College of Cardiology/American Heart Association Task Force on Clinical Practice Guidelines and the Heart Rhythm Society. *J Am Coll Cardiol*, Vol. 74, No. 1, pp. 104–132, 2019.
3. Nileshkumar J Patel, et al. Contemporary trends of hospitalization for atrial fibrillation in the united states, 2000 through 2010: implications for healthcare planning. *Circulation*, Vol. 129, No. 23, pp. 2371–2379, 2014.
4. Hiroshi Inoue, et al. Prevalence of atrial fibrillation in the general population of japan: an analysis based on periodic health examination. *Int. J. Cardiol.*, Vol. 137, No. 2, pp. 102–107, 2009.
5. Jelena Kornej, et al. Epidemiology of atrial fibrillation in the 21st century: Novel methods and new insights. *Circ. Res.*, Vol. 127, No. 1, pp. 4–20, 2020.
6. Giuseppe Boriani, et al. Asymptomatic atrial fibrillation: clinical correlates, management, and outcomes in the EORP-AF Pilot General Registry. *Am J Med*, Vol. 128, No. 5, pp. 509–518, 2015.
7. Masahiro Esato, et al. Clinical Impact of Asymptomatic Presentation Status in Patients With Paroxysmal and Sustained Atrial Fibrillation: The Fushimi AF Registry. *Chest*, Vol. 152, No. 6, pp. 1266–1275, 2017.
8. Jonathan S Steinberg, et al. Thirty-Second Gold Standard Definition of Atrial Fibrillation and Its Relationship With Subsequent Arrhythmia Patterns: Analysis of a Large Prospective Device Database. *Circ Arrhythm Electrophysiol*, Vol. 11, No. 7, p. e006274, 2018.
9. Toshitaka Yamakawa, et al. Wearable Epileptic Seizure Prediction System with Machine-Learning-Based Anomaly Detection of Heart Rate Variability. *Sensors (Basel)*, Vol. 20, No. 14, 2020.
10. Zachary I Attia, et al. An artificial intelligence-enabled ECG algorithm for the identification of patients with atrial fibrillation during sinus rhythm: a retrospective analysis of outcome prediction. *Lancet*, Vol. 394, No. 10201, pp. 861–867, 2019.
11. Xiaomao Fan, et al. Multiscaled Fusion of Deep Convolutional Neural Networks for Screening Atrial Fibrillation From Single Lead Short ECG Recordings. *IEEE J Biomed Health Inform*, Vol. 22, No. 6, pp. 1744–1753, 2018.
12. P. Langley, et al. Accuracy of algorithms for detection of atrial fibrillation from short duration beat interval recordings. *Med Eng Phys*, Vol. 34, No. 10, pp. 1441–1447, 2012.
13. Awni Y Hannun, et al. Cardiologist-level arrhythmia detection and classification in ambulatory electrocardiograms using a deep neural network. *Nat Med*, Vol. 25, No. 1, pp. 65–69, 2019.
14. Xiaochuan Du, et al. A novel method for real-time atrial fibrillation detection in electrocardiograms using multiple parameters. *Ann Noninvasive Electrocardiol*, Vol. 19, No. 3, pp. 217–225, 2014.
15. Tove Hygrel, et al. An artificial intelligence-based model for prediction of atrial fibrillation from single-lead sinus rhythm electrocardiograms facilitating screening. *Europace*, Vol. 25, No. 4, pp. 1332–1338, 2023.

16. Donghwan Yun, et al. Automatic segmentation of atrial fibrillation and flutter in single-lead electrocardiograms by self-supervised learning and Transformer architecture. *J Am Med Inform Assoc*, Vol. 31, No. 1, pp. 79–88, 2023.
17. Stijn Dupulthys, et al. Single-lead electrocardiogram Artificial Intelligence model with risk factors detects atrial fibrillation during sinus rhythm. *Europace*, Vol. 26, No. 2, 2024.
18. Shaun Giancaterino, et al. Current and future use of insertable cardiac monitors. *JACC Clin. Electrophysiol.*, Vol. 4, No. 11, pp. 1383–1396, 2018.
19. Rakesh Gopinathannair, et al. Novel algorithms improve arrhythmia detection accuracy in insertable cardiac monitors. *J. Cardiovasc. Electrophysiol.*, Vol. 34, No. 9, pp. 1961–1968, 2023.
20. Md Saiful Islam, et al. Robust detection of atrial fibrillation using classification of a linearly-transformed window of r-r intervals tachogram. *IEEE Access*, Vol. 7, pp. 110012–110022, 2019.
21. E. Petrucci, et al. The use of sequential rr distributions to detect atrial fibrillation episodes in very long term ecg monitoring. In *2006 Computers in Cardiology*, pp. 945–948, 2006.
22. Tania Pereira, et al. Photoplethysmography based atrial fibrillation detection: a review. *NPJ Digit. Med.*, Vol. 3, No. 1, p. 3, 2020.
23. Marco V Perez, et al. Large-Scale Assessment of a Smartwatch to Identify Atrial Fibrillation. *N Engl J Med*, Vol. 381, No. 20, pp. 1909–1917, 2019.
24. Jeremiah Wasserlauf, et al. Accuracy of the Apple watch for detection of AF: A multicenter experience. *J Cardiovasc Electrophysiol*, Vol. 34, No. 5, pp. 1103–1107, 2023.
25. S. A. Lubitz, et al. Detection of Atrial Fibrillation in a Large Population Using Wearable Devices: The Fitbit Heart Study. *Circulation*, Vol. 146, No. 19, pp. 1415–1424, 2022.
26. Nino Isakadze and Seth S. Martin. How useful is the smartwatch ECG? *Trends in Cardiovascular Medicine*, Vol. 30, No. 7, pp. 442–448, 2020 .
27. Diego Mannhart, et al. Clinical validation of 5 direct-to-consumer wearable smart devices to detect atrial fibrillation: Basel wearable study. *JACC: Clinical Electrophysiology*, Vol. 9, No. 2, pp. 232–242, 2023.
28. Marek Malik, et al. Guidelines heart rate variability - standards of measurement, physiological interpretation, and clinical use. *Eur. Heart J.*, Vol. 115, No. 5, pp. 354–381, 1996.
29. Koichi Fujiwara, et al. Epileptic seizure prediction based on multivariate statistical process control of heart rate variability features. *IEEE Trans. Biomed. Eng.*, Vol. 63, No. 6, pp. 1321–1332, 2016.
30. Ayako Iwasaki, et al. R-R interval-based sleep apnea screening by a recurrent neural network in a large clinical polysomnography dataset. *Clin Neurophysiol*, Vol. 139, pp. 80–89, 2022.
31. Koichi Fujiwara, et al. Heart Rate Variability-Based Driver Drowsiness Detection and Its Validation With EEG. *IEEE Trans Biomed Eng*, Vol. 66, No. 6, pp. 1769–1778, 2019.
32. Yuki Yoshi Sumi, et al. Resting Heart Rate Variability Is Associated With Subsequent Orthostatic Hypotension: Comparison Between Healthy Older People and Patients With Rapid Eye Movement Sleep Behavior Disorder. *Front Neurol*, Vol. 11, p. 567984, 2020.
33. Shota Saeda, et al. Blunted tachycardia and cardiac sympathetic denervation in isolated rapid eye movement sleep behavior disorder. *BMC Neurol.*, Vol. 24, No. 1, p. 317, September 2024.
34. Koshi Ota, et al. Frustration control during driving using auditory false heart rate feedback. *Transportation Research Part F: Traffic Psychology and Behaviour*, Vol. 101, pp. 375–386, 2024.
35. Koichi Fujiwara, et al. Driver drowsiness detection using r-r interval of electrocardiogram and self-attention autoencoder. *IEEE Transactions on Intelligent Vehicles*, Vol. 9, No. 1, pp. 2956–2965, 2024.
36. San Ha Kim, et al. Higher heart rate variability as a predictor of atrial fibrillation in patients with hypertension. *Sci Rep*, Vol. 12, No. 1, p. 3702, 2022.
37. Mohammadali Habibi, et al. Resting Heart Rate, Short-Term Heart Rate Variability and Incident Atrial Fibrillation (from the Multi-Ethnic Study of Atherosclerosis (MESA)). *Am J Cardiol*, Vol. 124, No. 11, pp. 1684–1689, 2019.

38. Hyun Jae Baek, et al. Reliability of ultra-short-term analysis as a surrogate of standard 5-min analysis of heart rate variability. *Telemed J E Health*, Vol. 21, No. 5, pp. 404–414, 2015.
39. Jin Woong Kim, et al. Is Ultra-Short-Term Heart Rate Variability Valid in Non-static Conditions? *Front Physiol*, Vol. 12, p. 596060, 2021 .
40. Joel S Burma, et al. The validity and reliability of ultra-short-term heart rate variability parameters and the influence of physiological covariates. *J Appl Physiol*, Vol. 130, No. 6, pp. 1848–1867, 2021.
41. Rosangela Akemi Hoshi, et al. Poincaré plot indexes of heart rate variability: relationships with other nonlinear variables. *Auton Neurosci*, Vol. 177, No. 2, pp. 271–274, 2013.
42. Koichi Fujiwara, et al. Over- and Under-sampling Approach for Extremely Imbalanced and Small Minority Data Problem in Health Record Analysis. *Front Public Health*, Vol. 8, p. 178, 2020.
43. Omer Sagi and Lior Rokach. Ensemble learning: A survey. *WIREs Data Mining and Knowledge Discovery*, Vol. 8, No. 4, p. e1249, 2018.
44. Yoav Freund and Robert E. Schapire. A decision-theoretic generalization of on-line learning and an application to boosting. *Journal of Computer and System Sciences*, Vol. 55, No. 1, pp. 119–139, 1997.
45. Haibo He and Eduardo A. Garcia. Learning from imbalanced data. *IEEE Transactions on Knowledge and Data Engineering*, Vol. 21, No. 9, pp. 1263–1284, 2009.
46. Chris Seiffert, et al. Rusboost: A hybrid approach to alleviating class imbalance. *IEEE Trans. Syst., Man, Cybern. A, Syst., Humans*, Vol. 40, No. 1, pp. 185–197, 2010.
47. Tianqi Chen and Carlos Guestrin. Xgboost: A scalable tree boosting system. *CoRR*, Vol. abs/1603.02754, 2016.
48. <https://support.apple.com/en-us/HT208955>.

〈 発 表 資 料 〉

題 名	掲載誌・学会名等	発表年月
IoT-Based Atrial Fibrillation Screening System, Development and Prospective Study	IEEE Internet of Things Journal	2025 年 1 月

