

ECG-Based Deep Learning and Clinical Risk Factors to Predict Atrial Fibrillation

(心電図に基づいた深層学習と臨床危険因子を用いた、心房細動発症予測に関する検討)

Shaan Khurshid , MD, MPH*; Samuel Friedman, PhD*; Christopher Reeder , PhD; Paolo Di Achille , PhD; Nathaniel Diamant, BS; Pulkit Singh, BA; Lia X. Harrington, PhD; Xin Wang, MBBS, MPH; Mostafa A. Al-Alusi, MD; Gopal Sarma, MD, PhD; Andrea S. Foulkes , ScD; Patrick T. Ellinor , MD, PhD; Christopher D. Anderson , MD, MMSc; Jennifer E. Ho , MD; Anthony A. Philippakis, MD, PhD; Puneet Batra , PhD; Steven A. Lubitz , MD, MPH

Circulation. 2022;145:122–133.

DOI: 10.1161/CIRCULATIONAHA.121.057480

背景：人工知能 (AI) を用いた 12 誘導心電図の解析は心房細動 (AF) の発症を効率的に予測することを可能にすると考えられている。予測精度において、臨床的な危険因子を上回る意義があるか、または、一般化される価値があるかは未だ十分な検討がなされていない。

方法：Massachusetts General Hospital (MGH)において長期に経過観察されている症例の 12 誘導心電図を用いて、5 年間の AF 発症を予測するための畳み込み神経回路 (ECG-AI)を構築した。本研究では、ECG-AI による 5 年 AF 発症リスク、Cohorts for Heart and Aging in Genomic Epidemiology–Atrial Fibrillation (CHARGE-AF) リスクスコア、ECG-AI と CHARGE-AF の両方を併せた CH-AI からなる 3 つの Cox 比例ハザードモデルを適用した。モデルの性能は、ROC 曲線下面積や MGH 内部と二つの外部施設 (Brigham and Women’s Hospital [BWH] and UK Biobank) のキャリブレーションによって評価した。

モデルは、UK Biobank の観察可能限界を考慮して 2 年の AF 発症リスクを予測するよう再調整された。ECG-AI リスク予測に最も影響する 12 誘導心電図の所見を特定するために顕著性マッピングを使用し、ECG-AI と CHARGE-AF の線形予測因子について評価した。

結果：トレーニングセットは、45770 症例 (年齢 55 ± 17 歳、女性 53%、2171 AF イベント) から成り、テストセットは 83162 症例 (年齢 59 ± 13 歳、女性 56%、2424 AF イベント) から成る。ROC 曲

線下面積の比較は、CHARGE-AF を用いると MGH で 0.802 [95% CI, 0.767–0.836], BWH で 0.752 [95% CI, 0.741–0.763], UK Biobank で 0.732 [95% CI, 0.704–0.759]であった。また、ECG-AI を用いると MGH で 0.823 [95% CI, 0.790–0.856], BWH で 0.747 [95% CI, 0.736–0.759], UK Biobank で 0.705 [95% CI, 0.673–0.737]であった。

ROC 曲線下面積は、CH-AI を用いた場合が最大となり、MGH で 0.838 [95% CI, 0.807 to 0.869], BWH で 0.777 [95% CI, 0.766 to 0.788], UK Biobank で 0.746 [95% CI, 0.716 to 0.776]であった。校正エラーは、ECG-AI を用いた場合 (MGH, 0.0212; BWH, 0.0129; UK Biobank, 0.0035) と CH-AI を用いた場合 (MGH, 0.012; BWH, 0.0108; UK Biobank, 0.0001) で低値であった。顕著性分析では、AI モデルの予測に ECG 上の P 波が最も大きく影響していた。ECG-AI と CHARGE-AF の線形予測因子は関連していた (Pearson r: MGH, 0.61; BWH, 0.66; UK Biobank, 0.41)。

結論：AI による 12 誘導心電図分析を用いた予測は、AF の発症に関して臨床的な危険因子を用いた予測と同様に有効であり、また両者は相互に補完するものである。ECG-AI は、AF 発症を効率的に定量化しかつ予測できる可能性がある。

解釈：AI を用いた心電図解析により、脳梗塞予防につながる心房細動発症の予測 (Attia ZI, et al. Lancet. 2019;394:861-867) 以外にも低心機能症例の同定 (Attia ZI, et al. Nat. Med. 2019;25:70-74)、血清カリウムの変動を来しやすい透析患者における血清カリウム値の予測 (Attia ZI, et al. J Am Heart Assoc. 2016;5: e002746)、肥大型心筋症症例の同定 (Ko WY, et al. J Am Coll Cardiol.2020;75:722-733)、閉塞性睡眠時無呼吸症候群の診断 (Erdenebayar U, et al. Comput. Methods Prog. Biomed. 2019;180:105001) が可能であることが過去に報告されており、今後も予測能の向上や分野の拡大が期待されている。この文献は臨床的な危険因子（年齢、性別、身長、体重、収縮期/拡張期血圧、喫煙、降圧薬の内服、糖尿病、うっ血性心不全の既往、心筋梗塞の既往）から AF の発症を予測する CHARGE-AF スコア (Alonso A, et al. J Am Heart Assoc. 2013 Mar 18;2:e000102) と AI による ECG 解析について比較検討した点が新しく、心電図が多く情報を反映する検査手段であることを再認識した。心房細動の発症予測がより簡便になり、生活習慣の改善から発症予防が促進されることが期待される。