

深度学习在 ECG 信号处理中应用综述

摘要：随着计算机运算速度的大幅度提升，深度学习（Deep Learning, DL）在计算机视觉、自然语言处理和大数据处理等方向取得了非常好的成绩。最近，深度学习作为最新技术应用于生物信号处理。心电图（Electrocardiogram, ECG）是生物信号中重要的一部分，在检测心脏疾病，预防因心肌梗塞而引起猝死方面具有重大意义。与传统机器学习相比，深度学习具有自适应和自学习的特点，在 ECG 特征提取、分类、发现病症等方面更为优秀。同时，为了更好地训练深度学习模型，需要“大数据”规模数据集用于训练。基于以上特点，本文选取近五年发表的以深度学习和心电图为关键词的论文，统计研究病症、使用方法和最后结果。为了方便快速入门，首先介绍了心电相关知识。再对论文中使用的 DL 方法如卷积神经网络（CNN）、循环神经网络(RNN)和其他方法的创新点进行介绍。最后，介绍了深度学习在心电图方面的应用和未来研究方向。

关键词：深度学习、心电图、CNN、RNN、DNN

1. 介绍

随着人工智能的发展，深度学习技术也用在越来越多的领域，其进展包括图像和语音识别^{1、2、3、4}，自然语言处理^{5、6}和语言翻译^{7、8}。现在，深度学习技术也广泛运用于医疗行业，包括健康信息学⁹、生物医学¹⁰和生物信息学¹¹等学科。




图 1 心脏跳动与心电图对应关系¹²

本文要研究的是生物信息学中的心电图部分。心电图和心脏跳动关系可见图 1 心脏跳动与心电图对应关系。通过心电图可以反应心脏情况，发现心脏相关疾病如心律失常。心律失常属于心血管疾病。一般来说，心血管疾病有三大

类：心律失常引起电紊乱、血管紊乱导致的循环不畅和身体结构上的心肌疾病¹³。心脏病是导致人们死亡的头号杀手，美国每年约有 150 万人发生心肌梗死。据报道，大约每 40 秒，美国的成年人就会有心肌梗死或中风。2016 年全球主要死因心血管疾病的死亡人数每年超过 1760 万人，预计到 2030 年将增加到 2360 万人以上¹⁴。心率失常分为缓慢、快速或不规则心跳，又可分为危及生命和不危及生命类型^{15、16}。心律失常的诊断需要对个体心脏搏动中正常和异常部分进行识别，并对心电图进行准确标注，但是由于心电图具有时间长，有的心电图长达 24 小时；数据量大，每 24 小时可产生十万左右心博记录；重复性高，包含病症的心电图可能只占心电图的一少部分。因此，用人工的方法看完所有的心电图显然是不可能的，那么就需要借助计算机来完成这个工作。

深度学习方法目前广泛用于医疗行业，早些时候，ECG 就有用传统机器学习方法进行分类的研究，目前也有很多研究人员将心电图运用到 CNN 中进行病症分类。比如 Yuzhen 等人采用 BP 神经网络对心电图进行分类，分类准确率达 93.9%¹⁷。Ceylan 团队采用前馈神经网络作为分类器，实现了四种不同心律失常的检测，平均准确率为 96.95%¹⁸。Beyli 团队提出了一种基于特征向量特征提取的递归神经网络（RNN）分类器¹⁹。结果表明，该模型对 4 种不同心律失常平均准确率达 98.06%。Park 团队提出了一种 K 近邻（K-NN）分类器，用于检测 17 种类型的心电图，平均灵敏度为 97.1%，特异性为 98.9%²⁰。Kiranyaz 团队引入一维 CNN 网络对心电信号进行分类，利用 CNN 对一维心电信号进行特征提取²¹。Rajpurkar 团队提出了一个一维 CNN 分类器，它比 Kiranyaz 的 CNN 模型具有更深入和更多的数据²²。Yildirim 团队设计了一种新的一维 CNN 网络模型，对 17 种心律失常疾病的识别率达到 91.33%²³。Acharya 团队开发了一个九层深的 CNN，可以自动识别五种不同的心跳类型，他们提出的模型在原始心电图和无噪心电图中的准确率分别达到 94.03% 和 93.47%²⁴。后来 Acharya 团队改进 U-net 模型，对 MIT-BIH 心律失常数据库中的心电图进行逐时分析，诊断心脏病的准确率高达 97.32%²⁵。Tan 团队利用 CNN 实现 LSTM，利用 ECG 信号自动准确诊断冠心病⁷⁹。Hwang 团队提出了一种用于分析心电信号来监测人类心理状态的深度学习框架²⁶。

本文主要统计了 2015 年到 2019 年发表的与深度学习和心电图有关的论文，在 web of science、IEEE explore 和 springer 上以深度学习、心电图为关键词选取高引用和最新论文，并基于这些论文对里面研究病症，使用方法和数据来源进行介绍。本文在第二节介绍了心电图的概念，心电图对医学上的帮助作用以及心电数据集的分布状况，方便读者对心电信号有基本了解并在需要使用数据集时可以快速准确找到自己需要的数据。第三节对目前在论文中使用到的几种神

电极名称	电极位置
LA	左上肢
RA	右上肢
LL	左下肢
RL	右下肢
V1	第 4 肋间隙胸骨右缘
V2	第 4 肋间隙胸骨左缘
V3	V2 导联和 V4 导联之间
V4	第 5 肋间隙左锁骨中线上
V5	第 5 肋间隙左腋前线上
V6	第 5 肋间隙左腋中线上
V7	第 5 肋间隙左腋后线上
V8	第 5 肋间隙左肩胛下线上
V9	第 5 肋间隙左脊柱旁线上
V3r	V1 导联和 V4r 导联之间
V4r	第 5 肋间隙右锁骨中线上
V5r	第 5 肋间隙右腋前线上




表 1 电极名称及安放位置

图 2 各导联心电监测位置示意图

神经网络方法做了方法介绍。在第四节本文介绍心电图在深度学习中的应用，总结了不同论文在使用深度学习网络时解决的关于心电方面的问题。最后在总结部分提出未来心电图研究方向和可以去做的工作。在文章最后附录部分，给出了统计的 50 篇论文发表年份、研究病症、使用方法、数据来源和最后结果。表格见附录 1 50 篇论文内容统计。

2. 心电信号介绍

心电图是通过机器测得每一次心脏跳动时产生的电信号，通过心电图可以检测是否有心率失常状况，原理是心肌细胞内外带有正电荷的阳性离子和带有负电荷的阴性离子因为心肌细胞活动而产生电极差，从而生成电信号。

2.1. 心电信号收集与解释

心电图需要从人身上获取数据，但是心脏不同于其他检测方式，心脏是一个立体的结构，仅通过一次测量无法测得心脏各个面的运动状况，因此为了反应心脏不同面的电活动，在人体不同部位放置电极，以记录和反应心脏的电活动。心脏电极的安放部位如表 1 体表电极名称及安放位置。常规心电图检查由 4 个肢体导联电极和 V1~V6 的 6 个胸前导联电极组成，通过肢体导联测得共 6 个标准双极导联（I、II 和 III）和加压导联（aVR、aVL 和 aVF），记录常规 12 导联心电图²⁷。12 导联位置见图 2 12 导联心电监测位置示意图。在目前的研究里，已经有很多基于单导联的研究，单导联容易特征提取，但




图 3 心电图各波段示意图

是可识别病症有限，而多导联虽然包含更多病症，却需要增加输入的维度，使网络结构更加复杂，因此多导联的研究还处于开始阶段。在统计论文中大部分是基于单导联的研究，仅有几篇关于多导联的研究。

心电图由 P-QRS-T 波段组成，在目前的研究里，由于 P、T 波段较为平缓，不容易定义，因此首先定位 R 波，部分论文在数据预处理阶段首先定位 R 波，再通过以 R 波为中心，向前向后提取部分时段心电图作为输入，或者通过 RR 间隙对心电图进行预处理进行试验。经过监测的心电信号如图 3 心电图各波段示意图所示，通过研究不同的波段可以检测不同的病症。各波段在心脏疾病方面意义如下²⁷：

P 波：心脏跳动由窦房结开始，正常心脏的电激动开始也于窦房结。窦房结位于右心房与上腔静脉的交界处，首先窦房结的激动传导到右心房，通过房间束传到左心房，形成心电图上的 P 波。一般来说 P 波时限为 0.12 秒。P 波代表了心房的激动，前半部为右心房激动，后半部为左心房的激动。当心房扩大，两房间传导出现异常时，P 波展现高尖或双峰 P 波。

PR 间期：当窦房结产生的兴奋经由心房、房室交界和房室束到达心室并引起心室肌开始兴奋时的时间为 PR 间期，又称房室传导时间。正常 PR 间期在 0.12~0.20 秒。若心房到心室的传导出现阻滞，则 PR 间期有延长或 P 波之后心室波消失。

QRS 波群：PR 间期后激动继续向下形成 QRS 波群，代表经希氏束、左右束支同步激动左右心室。QRS 波群代表了心室的除极，其激动时限小于 0.11 秒。

若有心脏左右束枝的传导阻滞、心室扩大或肥厚等情况，则 QRS 波群出现增宽、变形和时限延长。

ST 段：此时各部位的心室肌都处于除极状态，复极尚未开始，细胞之间并没有电位差。正常情况下 ST 段应处于等电位线上。当某部位的心肌出现缺血或坏死的表现时，会出现心室在除极完毕后仍有电位差，心电图上 ST 段发生偏移。

T 波：心室开始复极。在 QRS 波主波向上的导联，T 波应与 QRS 主波方向相同。心电图上 T 波的改变受多种因素的影响。例如心肌缺血时可表现为 T 波低平倒置。T 波的高耸可见于高血钾、急性心肌梗死的超急性期等。

QT 间期：代表了心室从除极到复极的时间。正常 QT 间期为 0.44 秒。QT 间期的延长一般与恶性心律失常发生有关。

2.2. 病症分类

心电图目前作为临床最常用检测之一，除了正常记录人体心脏电活动，还可以诊断多种病症，预防心脏问题。在本文统计的论文中，不同的论文都是对心律失常进行研究，但是研究病症和心电节拍分类的类型各有不同。本文从病症和心电节拍两方面将这些研究进行统计并介绍论文中研究的病症和心电节拍，方便读者在未来进行心电中病症研究时，可以参考目前研究情况选择自己研究的病症。病症统计图见图 4 关于心电病症研究方向。

1) 基于病症的研究：

心房颤动(AF)：是一种危及生命的心律失常，如果不能检测出来，可能会导致中风或心力衰竭。AF 发生在心房失去正常律动并杂乱的跳动时。在

心电病症研究




图 4 关于心电病症研究方向

美国有超过 230 万人和 600 万欧洲人患有各种类型的房颤²⁸。

阵发性心房颤动(PAF)：是房颤的一种，表现为心房运动不协调。PAF 偶尔发生，需要几分钟到几天的时间才能停止。有时，PAF 患者没有任何明显的症状，在临床监测过程中无法检测到。为了避免 PAF 诊断不及时，减少早期风险，医生建议使用 ECG 可穿戴设备对患者进行日常监测。

心房扑动 (ACG)：一般发生在房性心动过速之后与心房颤动之前，与 p 波有关，长期发展会导致房颤或房扑。

心室颤动 (VF)：是指心室发生无序的激动，致使心室规律有序的激动和舒缩功能消失，会导致心脏暂时停跳，是致死性心律失常。其心电图及其不规则以至于无法辨认 P、QRS、ST 段与 T 波。

充血性心力衰竭 (CHF)：当心排血量不能满足机体代谢的需要时而导

AAMI 分类	MIT-BIH 心拍	心拍解释
N	N L R e j	正常搏动(Normal beat) 左束支传导阻滞 (Left bundle branch block beat) 右束支传导阻滞 (Right bundle branch block beat) Atrial escape beat 交界性逸搏 (Nodal (junctional) escape beat)
S	A a x j	房性早搏 (Atrial premature beat) 异常房性早搏 (Aberrated atrial premature beat) Non-conducted P-wave (blocked APB) 交界性逸搏 (Nodal (junctional) escape beat)
V	V E !	室性早搏 (Premature ventricular contraction) 室性逸搏 (Ventricular escape beat) Ventricular flutter wave
F	F	心室融合心跳 (Fusion of ventricular and normal beat)
Q	Q f	未分类心跳 (Unclassifiable beat) Fusion of paced and normal beat
	B / r n ?	传导阻滞心搏 Bundle branch block beat (unspecified) 起搏心搏 Paced beat R 落在 T 上的室性早搏 R-on-T premature ventricular contraction 室上性逸搏 Supraventricular escape beat (atrial or nodal)

表 2AAMI 对应 MIT-BIH 心拍分类

致组织、器官血液灌注不足。如果治疗不及时，将导致心脏功能不全并加重症状。

冠状动脉疾病 (CAD)：胆固醇、脂肪在动脉中形成沉积，使通道变窄，导致心脏跳动变快，当流向心肌的血液由于血栓阻塞了一条冠状动脉而突然大量减少，就会心脏病发作。

心脏性猝死 (SCD)：是指由于各种心脏原因，引起的以意识丧失为先导的自然死亡，发现之前往往没有征兆，一旦发生，会因有效营救时间太短而导致死亡。

2) 基于心电节拍分类的研究：

目前使用的比较多的心电节拍分类是 AAMI 心电节拍分类标准和直接使用 MIT-BIH 中标注的心脏分类。

AAMI 标准：该数据库中存在的心跳类型分为 5 类：正常 (N)，室上性异位搏动 (SVEB)，室性异位搏动 (VEB)，融合搏动 (F) 和未知节拍 (Q)。

MIT-BIH 心电节拍类型：MIT-BIH 是目前最权威的数据库之一，其中数据自带心拍注释，MIT-BIH 数据库在心律失常分类上是独一无二的，其中心拍分类基于美国医疗器械协会 (AAMI) 标准建议的五组心律失常，MIT 和 AAMI 的对应心拍见表 2AAMI 对应 MIT-BIH 心拍分类。

其他：在别的数据集内，根据数据集注释的不同，其心电节拍分类有自己的标准，如对 17 类进行异常分类，对 8 种心脏异常进行分类等。

2.3. 心电数据库介绍

目前国际上最重要的，具有权威性的心电数据库有四个：美国麻省理工学院与 Beth Israel 医院联合建立的 MIT-BIH 心电数据库；美国心脏学会的 AHA 心律失常心电数据库；欧盟的 CSE 心电数据库和欧盟 ST-T 心电数据库。除此之外国际上被广泛认可的还有 Sudden Cardiac Death Holter Database, PTB Diagnostic ECG Database, PAF Prediction Challenge Database 等心电数据库。在本文统计的数据库里，通过对 50 篇论文进行统计，得到各论文数据来源，见图 5 论文数据来源统计。

在做研究时，通过权威数据库得出的与他人研究的结果才是有对比性，获得专业人士认可的。所以在数据的选择上，一方面要有自己的数据集，另一方面也要用权威公开数据集。论文来源包括公开数据集、医疗相关搜索网站等。从统计中可以看出，大部分的论文都使用了 MIT-BIH 数据集，也有使用实验室收集的未公开数据集进行的研究。或者使用数个数据集中的数据做实验。

数据来源




图 5 论文数据来源统计

下面对论文中提到的数据来源进行介绍：

MIT-BIH: 美国的 MIT-BIH 心电数据库是目前在国际上应用最多的数据库，由很多子数据库组成，每个子数据库包含某类特定类型的心电记录，其中应用的最多的是 MIT-BIT 心律不齐数据库和 MIT-BIT QT 数据库，在本节最后对 MIT-BIH 数据库进行详细介绍。

Kaggle: Kaggle 是 Anthony Goldbloom 2010 年在墨尔本创立的，是一个举办机器学习竞赛、托管数据库、编写和分享代码的平台，同时在 kaggle 数据库中也有心电图数据，包括心律失常（arrhythmia）、正常窦（normal sinus）、二级房室传导阻滞（second degree AV block）、一级房室传导阻滞（first degree AV block）、心房扑动（atrial flutter）、心房颤动（atrial fibrillation）、恶性心室（malignant ventricular）、室性心动过速（ventricular tachycardia）和心室二联律（ventricular bigeminy）。

PhysioNet 提供免费的网站访问记录生理信号的数据库（PhysioBank）和相关的开源软件（PhysioToolkit）。是数据检索网站。

Physibank: 目前包括多参数的心肺功能，神经，和其他生物学信号从各种主要的公众健康的影响，包括心脏猝死，充血性心脏衰竭，癫痫，步态失调，睡眠呼吸暂停的条件与健康受试者和患者数据库。提供一个拥有 50 个心电信号的数据库，共 10000 个心电信号数，其中大部分数据都是免费提供的，可以从网站上直接下载。

PTB (Physikalisch Technische Bundesanstalt): 德国联邦物理技术研究院（PTB）成立于 1887 年，是世界闻名的计量和测试科研机构，主要任务是进行计量学基础研究和应用技术开发，其中设有医学物理学。

自有数据集：从各大医院得到的数据集或者通过仪器测试得到数据集。

竞赛数据集：每年世界会举行众多医疗和计算机相关竞赛并提供数据集，比如中国 ECG 智能竞赛、心脏病学计算（CinC）挑战赛、PAF 预测挑战数据库。

其他：Holter 和 kaggle 得到的数据集。

除了上述的数据来源外，还有很多目前得到广泛认可的公开数据集，以下为简要概述：

AHA(American Heart Association)：由美国国家心肺及血液研究院资助的美国心脏协会开发了 AHA 心律失常心电数据库，该数据库的开发目的是评价室性心律不齐探测器的检测效果。它包括 154 个真实病人的心电图记录，由不同机构捐赠，每个记录 3 小时，由 2 个导联信号组成。每次记录的最后 30 分钟记录有七种心律失常；

欧盟 CSE(Common Standards for Electrocardiography)：心电数据库包含 1000 例短时间的心电记录，采用 12 或 15 导联，主要开发目的是用于评价心电图自动分析仪的性能。

欧盟的 ST-T 数据库：是由欧洲心脏病学会(European Society ofCardiology)开发的，用于评价 ST 段和 T 波检测算法性能的数据库。该数据库由来自 79 名受试者的 90 个 2 小时记录片段组成，其中包括起源于心肌缺血、高血压、心室运动障碍和药物效应的异常；

ECG-ID：ECG-ID 是一个完全专注于生物测定的数据库。从 90 名受试者中收集了 20 秒的心电图记录，目前可在 PhysioNet 上获得。对于受试者，数据库在 6 个月内收集了 2 到 20 个记录（总共 310 个）。这些信号是通过手腕上的肢体钳夹电极从导联 I 获取的；

E-HOL 24 小时动态心电图仪：此 ECG 数据库来自 the University of Rochester²⁹。在 24 小时内，使用动态心电图仪监测 203 名健康受试者，其中 4 个电极放在胸部，3 个导联遵循伪正交配置；

MIT-BIH 是目前使用最广泛、最权威数据库之一，MIT-BIH 心律失常数据库包括 48 个部分，其中包含两个通道的心电图记录³⁰。这些部分是 1975 年至 1979 年在 Boston's Beth Israel Hospital 记录的，从 47（25 名男子和 22 名女子）人获得。每个部分的持续时间为半小时。男性为 32-89 岁，女性为 23-89 岁（在所有记录中，两份记录来自同一男性受试者）。采样率为每秒 360 个采样，在 10 mV 范围内数字化的分辨率为 11 位。

1) MIT-BIH 正常窦性心律数据库（MIT-BIH Normal Sinus Rhythm database）包含 18 份无明显心律失常患者的长期心电图记录。这些人是 5 名

男性，26-45 岁，13 名女性，20-50 岁。这些记录是在 Boston's Beth Israel Hospital 的实验室收集的，采样率为 128 赫兹

2) MIT-BIH 噪音压力测试数据库 (MIT-BIH Noise Stress Test database) 由 12 个半小时的心电图记录和 3 个半小时的噪音心电图记录组成。这些心电图记录是通过在 the MIT-BIH Arrhythmia Database 中未受污染的心电图信号中加入调整量的噪声而产生的。

3) MIT-BIH 房颤数据库 (MIT-BIH Atrial Fibrillation database) 包含 25 个患有房颤疾病的人的长期心电图信号。采样率为 250hz，数字化分辨率为 12 位，间隔为 $\pm 10\text{mv}$

4) MIT-BIH T 波交替挑战数据库 (MIT-BIH T-Wave Alternans Challenge database) 覆盖 100 条心电图记录。采样率为 500 赫兹，数字化分辨率为 16 位，间隔为 ± 32 毫伏。患有心肌梗死、短暂性缺血、室性心动过速等与心源性猝死有关的疾病的患者均已给出心电图信号。该数据库还包括健康对照组和合成病例，以及调整后的 T 波改变量。每条记录的持续时间为两分钟。

5) MIT-BIH 室上性心律失常数据库 (MIT-BIH Supraventricular Arrhythmia database) 由 78 个半小时的心电图记录组成，选择这些记录将室上性心律失常病例添加到 MIT-BIH 心律失常数据库中。心电信号采样率为 128hz，数字化分辨率为 10 位。

6) MIT-BIH 恶性室性心律失常数据库 (MIT-BIH Malignant Ventricular Arrhythmia database) 包含 22 个患有室性心动过速、室颤和室颤发作的人的心电图记录。采样率为 250hz，数字化分辨率为 12bit。

7) MIT-BIH 长期数据库由 7 个长期心电图记录组成。每个记录的持续时间为 14-22 小时。采样频率为 128 赫兹，2 导联和 3 导联心电图记录的数字化分辨率为 12 位。

8) MIT-BIH-ST 变化数据库 (MIT-BIH Long Term database) 包括 28 个心电图记录。每个记录的持续时间在 13 到 67 分钟之间。这些记录是在训练过程中收集的，包括瞬时 ST 段压低。除此之外，最后五条记录还包括 ST 高程。采样率为 360 赫兹

3. 深度学习在心电图中应用

到目前为止，有许多方法被用于心电图的自动分类，如频率分析 (frequency analysis)³¹、k 近邻聚类 (k-Nearest Neighbor clustering)³²、混合专家法 (mixture-of-experts method)³³、分类和回归树 (Classification and Regression Trees)^{34, 35}、人工神经网络 (Artificial Neural Networks)³⁶、隐马尔

可夫模型（Hidden Markov Models）³⁷、支持向量机（SVM）³⁸、概率神经网络（Probabilistic Neural Networks）³⁹，recurrent NN（RNN）⁴⁰和路径森林（path forest）⁴¹。

但是随着深度学习方法的兴起，越来越多的领域被用到深度学习中，在 web of science 上以 ECG 和深度学习为关键词，获得 2019 年 190 篇，2018 年 183 篇，2017 年 54 篇，2016 年 27 篇。深度学习近几年在心电图中的研究大幅增长。在本文所统计的 50 篇论文中，研究重点有两个，第一是通过深度学习网络学习特征并对心电病症分类，第二是通过深度学习方法监测并获取心电节拍。

相比深度学习方法，使用传统的方法必须用带注释的心电图，而深度学习方法可以自动学习特征。因此，在选取的 50 篇论文中，统计了每个论文所使用的方法，并对其中用到的方法进行介绍。统计方法有两种，一种是当论文里用到多种深度学习方法时按照复合方法进行统计，比如当一篇论文用到 CNN 和 LSTM 两种方法时，按一种复合方法计算，另一种是分开统计，即 CNN 和 LSTM 各算一次，按复合方法统计方法总数为 50，按分开统计则总数大于 50。具体见图 6 深度学习方法统计。

从图中可以看到，CNN 和 LSTM 是使用最多的两种方法，这是因为目前对心电的研究大部分重点心拍分类和病症识别，用 CNN 可以很好的学习特征并分类，但是由于 CNN 各节点之间无联系，而心电图呈现具有时序性，所以 LSTM 也被用于心电病症识别。但是 LSTM 在这 50 篇论文中基本和 CNN 结合形成复合网络结构，而不是单独使用。

本文将使用最多的 CNN 和 RNN 作为单独章节，将所用到的方法横向介绍，其他方法在最后一块一起介绍。

3.1. 卷积神经网络

卷积神经网络（Convolutional Neural Networks, CNN）是一类包含卷积计算

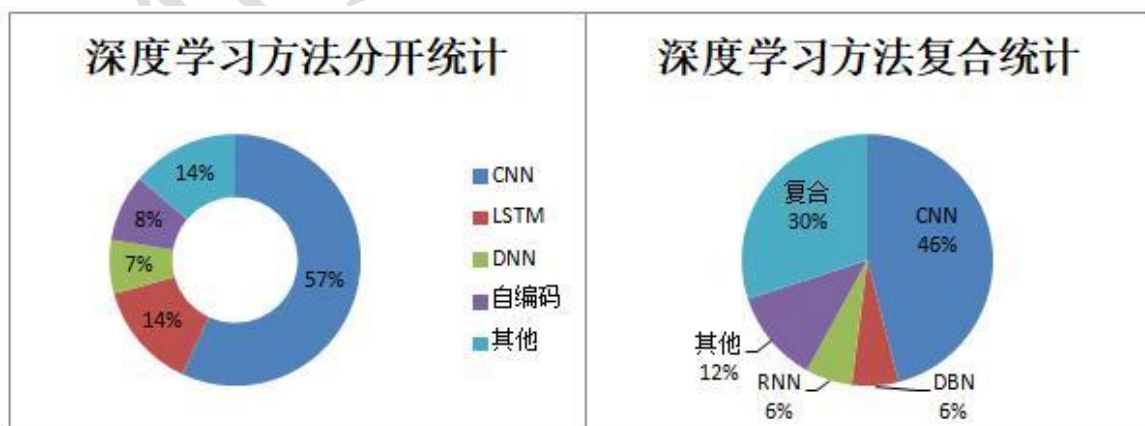


图 6 深度学习方法统计

且具有深度结构的前馈神经网络（Feedforward Neural Networks），是深度学习（deep learning）的代表算法之一^{42、43}。

在统计的论文中，基于 CNN 研究达到了半数以上，有部分研究是将 CNN 和 RNN 结合起来的复合网络，这一部分会放到下一节 RNN 网络介绍。

Ruggero Donida Labati⁷⁰ 设计了一个六层 CNN，将 ReLU（校正 Linear 单元）作为激活函数，由三层 Maxpool 连接，一层 Dropout 层，一层全连接层，最后一层是 softmax 层。ReLU 神经元的特性有利于更深入的表示。LRN 层与 ReLU 神经元组合可以得到无限的输出。LRN 层可以检测心电信号中各节拍邻接部分高频特征。这类似于神经生物学中侧向抑制的概念。此外，文中还使用了辍学正则化（dropout regularization），它通过随机地将激活的一部分设置为零来改善泛化和避免协同适应。

Shashikumar S P⁷⁴ 的 CNN 体系结构由三个连续卷积层和一个 max-pooling 层、两对连续卷积层和一个 max-pooling 层以及一个完全连接层组成。并建立一个弹性网络 logistic 模型，将每个患者分为两类房颤和非房颤，并使用 RMSProp 算法对整个模型的权重进行了优化，并对权重进行了 L1-L2 正则化。利用贝叶斯优化方法对整个模型的超参数（包括正则化因子和 CNN 中的滤波器个数）进行了优化。将每个测试集示例的预测结果概率汇总到所有集合中，来计算最终 AUC（area under curve）。

Xia Y⁷⁶ 在现有 CNN 基础上，提出一种基于深度 CNN 网络（DCNNs）的 AF 检测方法，DeepNet1 由三个卷积层、三个最大池层、两个 ReLU 层、一个退出层、两个完全连接层和一个 softmax 层组成。DeepNet2 由两个卷积层、两个最大池层、两个 relu 层、一个退出层、两个完全连接层和一个两个输出的 softmax 层组成。DeepNet1 和 DeepNet2 中使用的优化算法都是随机梯度下降（SGD）。此外，为了减少网络的参数数目，提高网络的非线性，采用了多层小尺度卷积核来代替大尺度卷积核。在训练之前，先计算所有训练样本的平均值，然后从样本中减去平均值，这样可以提高训练的速度和准确性。在随后的测试中，也可以从所有测试样本中减去平均值，这样就不需要重新计算测试样本的平均值。

Yildirim⁸⁰ 设计一个 16 层 CNN，由 7 个卷积层、4 个最大池层、两个 batch 层和一个 flatten、一个全连接、一个 SoftMax 层组成。

Acharya U R⁸¹ 提出 9 层 CNN，三个卷积层，三个 MaxPool 层，三个全连接层。

Ulas Baran Baloglu⁶³ 运用了一种端到端的 CNN 方法检测 12 导联中的心肌梗死，使用 10 层 CNN 模型。由四层卷积，两层池化，一层 Dropout，一层全连

接，一层 Flatten，一层 Softmax 组成。它们经过卷积层和最大值层转换成不同大小的特征地图。在全连接层中，通过学习这些特征图来对病症进行自动识别与分类。为了避免模型训练过程中的过度拟合，文中采用了 Dropout。通过 Dropout 在训练过程中随机关闭了 20% 的神经元。同时为防止过拟合，文中没有大量的训练模型。在每个训练周期，模型将检查整个训练数据集。

Bahareh Pourbabae⁶⁴ 设计了一个五层 CNN，将负对数似然 (NLL) 函数作为损失函数。并采用端到端 CNN 从归一化的心电信号中提取特征，并将其分为两类，仅利用 CNN 的前四层来获取特征向量，然后利用其他分类器(k 近邻、支持向量机和多层感知器)对提取的特征向量进行分类。

3.2. 循环神经网络

循环神经网络(Recurrent Neural Network, RNN)源自 1982 年 John Hopfield 提出的霍普菲尔德网络。不同于卷积神经网络结构由输入到输出端是线性的，节点之间无连接，RNN 网络可以记住之前的信息并通过前面的信息影响后面节点的输出，因此 RNN 一般用于自然语言处理中文本预测，比如一段话通过前面的信息预测后面会说什么。而 RNN 的时序性可以很好的学习心电信息中的特征，因此一般与 CNN 一起进行心电节拍分类。

长短期记忆网络⁴⁴ (Long Short-Term Memory, LSTM) 是 RNN 的一种，于 1997 年提出，LSTM 解决了 RNN 中长期依赖问题，LSTM 一般用来处理和预测在时间序列中间隔和延迟非常长的事件。

Yildirim⁷⁸ 设计了两种 LSTM 模型，第一种网络模型只有单向 LSTM 类型，简称为 DULSTM (deep bidirectional LSTM networks and wavelet sequences)。第二种模型包含两个双向 LSTM，简称为 DBLSTM (deep bidirectional LSTM network-based wavelet sequences)。除了这些网络层之外，还设计了一种新的输入层，称为小波序列(WS)。DULSTM-WS 和 DBLSTM-WS 是包含 WS 层的这些模型的版本。用于分类的 DLSTM-WS 网络。DULSTM-WS 具有一个 WS 输入层、两个单向 LSTM 层和两个全连接层。DBLSTM-WS 具有一个 WS 输入层、两个双向 LSTM 和两个全连接层。全连接层的激活函数分别为 RELU 和 Softmax。

Shashikumar S P⁷⁴ 将 CNN 和 LSTM 结合起来形成多层网络。通过两个卷积层后进入池化层，将输入的时间维度降低一半，传入双向 LSTM 层，在两个输入方向上学习远程上下文。在网络中引入 Nesterov 加速梯度 (NAG) 的 SGD 进行训练⁴⁵。并对其进行微调，使用 NAG 可以加快收敛速度，减少达到最优时所需的训练数。

Tan J H⁷⁹设计的模型由四层 CNN 加三层 LSTM 结合，CNN 包括两个卷积层、两个最大池层，排列方式为卷积、最大池、卷积、最大池。之后加入 3 层 LSTM 结构。

3.3. 其他网络

人工神经网络(ANN): ANN 是受生物神经元网络启发的计算算法，用于解决计算机视觉、自然语言处理和药物发现等方面的预测问题。它包括相互连接的人工神经元，其相互连接与可调权重相关；神经元由输入、输出和隐藏层组成；这种方法是广泛使用的模式分类器之一。Ebrahimzadeh E¹⁰⁷设计的分类器使用三层 MLP，用误差反向传播算法并调整学习率得到最佳分类效果。

深度信念网络 DBN: DBNs 由 Hinton 于 2006 年提出^{46, 47}，在图像分类和语音识别领域得到了很好的应用。DBN 由堆叠的 RBM 构成，并以贪婪的分层方式进行训练。

Sherin M. Mathews⁶²将 DBN 用于分类，使用 RBM 预训练初始深层神经网络的权值，并通过反向传播误差导数对权重进行微调。

深度字典学习 (RDDL): Majumdar A⁹⁶使用了一个新的方法，RDDL (robust deep dictionary learning) 适用于从被稀疏但较大的异常值(例如，比高斯分布更重的尾部的伪影和噪声)污染的信号中学习表示。这在 ECG 中很常见。RDDL 学习多级非线性字典来表示数据。并提出鲁棒的 L1 范数成本函数代替字典学习中通常采用的标准欧几里德成本函数。

深度参数共享网络: Ji J⁸⁸改进的深度参数共享神经网络 (deep parameter-sharing network) 是一种神经网络，它在传统的神经网络中插入参数共享神经层每个任务都可以使用任何现有的神经网络来提取其私有特征，并传输到的共享神经层。这个共享神经层的输出连接到每个任务自己的输出层，以生成自己的结果。

深度神经网络 (DNN): DNN 是一种具有 3 层以上的特殊人工神经网络，它固有地将特征提取和分类融合到一个信号学习体中，并直接构造决策函数。G.Sannino⁶⁹使用 7 层隐藏层达到最佳分类效果。DNN 分类器使用 ReLU 激活函数创建神经元层，输出层使用 softmax 函数，代价函数是交叉熵。

4. 深度学习在心电图中应用步骤

将心电数据应用于 CNN 网络中的步骤基本分为三步：（1）数据预处理，一般有压缩，降噪和分割；（2）特征提取，使用深度学习网络进行自动特征学习；（3）特征分类，通过提取出的特征进行分类。以上每一步都是一个研究方

向，同时也是最后分类结果输出的组成部分，影响着最后结果的准确度，接下来先明确一个评估标准，通过四个指标来评定最后分类结果，方便论文横向比较，之后对上述三个步骤进行简要概述。

在此之前，先明确一下结果评估标准，目前获得广泛应用的有四个指标：准确性（Accuracy，Acc）、敏感性（Sensitivity，Sen）、特异性（Specificity，Spe）和阳性预测率（Positive predictive rate）^{48、49、50}。准确性的定义是正确分类的拍数（心率异常 TP 和心率正常 TN）与分类的总拍数之比。敏感性表示正确识别的心率异常（VEBs or SVEBs）的比例，等于 TP 除以 TP 和识别错误识别的心率正常（FN）之和。特异性测量正确识别的心率正常（非 veb 或非 sveb）的比例，即 TN 与 TN 和错误识别心率异常（FP）之和的比率。阳性预测率是指所有检测到的心率异常中正确心率异常的比例，即 TP 与 TP 和 FP 之和的比值。这四个指标的值越高，表示分类性能越好。部分论文由 F₁ 分数计算，其值越高越好。它们由以下公式计算。

- 1) Accuracy = (TP + TN)/(TP + TN + FP + FN)
- 2) Sensitivity = TP/(TP + FN)
- 3) Specificity = TN/(TN + FP)
- 4) Positive predictive rate = TP/(TP + FP)
- 5) F₁ = (2 × Positive predictive rate × Sen)/(Positive predictive rate + Sen)

这五个指标广泛应用于各论文内被作为评价指标，可以作为与他人对比实验结果的评价标准。

4.1. 数据预处理

在采集心电图时，由于个体、仪器、环境等原因，将造成心电图一定程度的变形，这种变形会影响医生的判断，同时也不利于神经网络特征学习，因此在使用数据之前要对数据进行预处理。在数据预处理中，一般有两个步骤，一个是数据降噪，二为数据分割。有的还会进行数据压缩。典型的噪声包括电极运动伪影（EM）、肌肉伪影（MA）和基线漂移（BW）。

在统计的论文中，有在提出基于心电信号压缩的深卷积自编码（CAE）模型⁶⁶。或者首先使用稀疏约束的叠层去噪自编码器（SDAEs）⁸⁴去噪，再使用 DNN 进行分类。编码器在心电数据压缩方面得到广泛应用。

而数据预处理的另一方面是降噪，降噪使用的比较多的是小波变换^{51、52}与滤波器⁵³，在深度学习方面，Jilong Wang 使用生成对抗网络（GANs）进行数据降噪⁵⁴，将去噪信号的信噪比提高 62% 左右，并有效保留心电信号特征。即深度学习方法同样可以很好的应用在降噪方面。而分割首先要确定 R 峰的位置，有的 R 峰在数据库里已经标注出来，有的则需要通过一定的方法找出 R 峰，目

前使用传统机器学习就可以很好的找到 R 峰的位置了，一般不需要使用深度学习方法。

在 Andersen R S⁶⁵中使用了以下方法计算 RR 间隙。其中 $R_{peaks}(n)$ 是样本中第 n 个 R 峰的位置， f_s 是样本频率 (Hz)。

$$RRI(n) = \frac{R_{peaks}(n+1) - R_{peaks}(n)}{f_s},$$

G. Sannino⁶⁹ 通过 R 峰值检测对应于单个心跳。使用基于 Pan 和 Tompkins 的算法⁵⁵作为 QRS 检测器，并利用了斜率信息⁵⁶进行改进。

通过检测 R 峰提取各个心拍，进行下一步研究。

4.2. 特征提取与特征分类

在深度学习中，有使用一种方法同时完成特征提取和特征分类。同时，也有结合多种方法进行特征提取和分类。经过统计，本文总结出在各论文中特征提取和特征分类的方法并进行阐述。

CNN 信号目前被广泛用于病症特征提取和心电节拍分类。通过改进传统方法如 AlexNet 或者结合自编码、MLP、LSTM 等方法来达到更好的分类效果。在 50 篇论文中有 33 篇都使用到了 CNN。

在所统计的论文里，CNN 的使用方法有：CNN，CNN 结合 LSTM 形成复合网络，编码器和 CNN 组合形成带有降噪并能分类的复合网络，以及 CNN 结合传统机器学习方法对心电数据进行处理。其他方法也得到使用，比如 DBN、DNN、ANN 等方法。

总结起来，一般来说会使用自编码进行数据预处理，用于心电数据压缩。而 CNN、LSTM、DBN 等深度学习模型被用来学习特征。最后，用到传统 ANN 方法进行特征分类。

5. 未来工作

个体差异性：一个人的 ECG 随着血压、精神压力、体位、呼吸频率、年龄和体重而变化；来自相同病人的心拍按比例分配于训练集和测试集中，通过这样的设置可以得到很好地分类效果，在统计的论文中绝大部分都是这么做的。但是，在实际医疗诊断中，所训练的模型中的数据来自于一些旧的病人中已有标签的数据，而模型需要根据这些数据的规律去预测新的病人。这时，个体差异性的影响会体现出来，使得在旧病人数据上训练的模型，难以有效泛化到新病人的数据。解决这个问题是很困难的，由于没有定性的标准，目前还没有一个系统化的方案。

各波段数据提取：各波段包含病症不同，心电波的每一个部分都值得研究，但是由于有的波形不明显，不易于分割的特点，因此目前最多的研究还在 QRS 波。如何提取其他波形里的特征是面对的一大问题。

可解释性差：目前大受欢迎的神经网络系列模型为“黑盒”模型，虽然取得了良好的性能，但是模型的内在原理一直无法解释。这对医疗领域的影响尤其明显，对于与人生命及其相关的医疗行业，只有一个可解释的诊断结果才让人接受。

数据稀缺：医疗数据不像普通的数据那样容易获取，并且涉及到个人隐私问题。目前，包括 ECG 在内的智能医疗领域，还没有像计算机视觉领域 imagenet 那样公认的，有影响力的“大”数据集，这也限制了这个领域的发展。

结合多导联进行诊断：目前绝大多数心电研究都是基于单导联的，但现实情况是很多的心脏疾病需要联合多个导联才能诊断出来，这也是为什么目前的数据集仅能做少量分类的原因。多导联数据的处理和诊断目前才刚刚发展，对精度和病症的学习都有极大发展空间，并且相关公开数据集也非常缺乏，所以针对多导联心电研究也比较少。

多病诊断：患者可能患有多种心脏病，心电图如何表达，深度学习方法又如何检测？目前还没定论。

远程心脏状态监测：由于心脏病的突发性，对心脏的检测和预警非常有必要。通过轻便的可穿戴设备，实时检测、预警，对硬件和算法都有很高的要求，这是未来远程心电检测的发展趋势。

6. 结论

目前使用的比较多的是在医疗图像处理方面，由于心电图采集的特殊性，在数据方面就是个大难关，而心电图所蕴含的医疗价值非常大，对于预防人类心脏疾病，防止猝死都有很高的医疗价值和社会价值。随着计算机计算速度的飞速发展，深度学习再次走上历史舞台，虽然目前深度学习已经应用在很多方面，但是深度学习在医疗领域的研究还有很多改进之处。在此之前，关于深度学习和医学信号方面的综述已经有很多，但是基于心电信号的深度学习方法使用还寥寥无几，至少到目前为止，还没有查到有相关综述的发表，因此，本文统计了与深度学习和心电图有关的 50 篇论文。对研究中最重要数据来源、使用方法和研究步骤都进行了统计与总结。为了方便读者对 50 篇论文内容有大概了解，将所挑选论文的研究病症、使用方法、数据来源和最终结果进行简要统计并放于文末附录部分。方便查阅和对比。

深度学习在心电的研究才刚刚起步，在数据来源方面，目前使用的比较多的是 MIT-BIH 数据库，其次是 PhysioNet 网站上搜寻到的数据，同时，使用自

有数据的研究也有许多。在研究病症方面，关于心脏疾节拍分类的研究也多基于 AAMI 标准，而心脏疾病方面基于房颤、房扑和心扑的研究是最多的。在使用方法中，CNN 的使用是最多的，其次是 LSTM。在未来，基于多导联的心脏疾病联合检测和远程心脏状态实时检测将成为未来的难关和重点，但在此之前，研究者必须解决数据问题，以及对于个体的研究是否可以应用于医疗实践，对每一个个体能精准识别，这都是未来研究热点。

附录：

附录 1 50 篇论文内容统计

序号	论文	病症	方法	数据来源	结果
1	Shalin S ⁵⁷ 2018	心动过速、心动过缓、室上性心律失常和心室	4 层 CNN, MLP 用于分类	physibank.com 和 kaggle.com	Acc 为 88.7%，CNN 的 Acc 为 83.5%
2	Xia Y ⁵⁸ 2018	SVEB 和 VEB	深度神经网络 (DNN) 后验概率	MIT-BIH 心律失常数据库和可穿戴设备的心电图数据	三个最佳平均测试结果 0.8552 0.9176 0.7827
3	Ribas Ripoll V J ⁵⁹ 2016	正常、边缘正常和异常 ECG	CNN, 包含三个隐藏层	巴塞罗那的 Clínic 医院进行	Acc: 0.8552; Spe: 0.7827
4	Xiong Z ⁶⁰ 2017	房颤 (AF)	16 层一维 CNN 网络	心脏病学计算 (CinC) 挑战赛	Acc: 正常: 90%, AF: 82%, 其他: 75%
5	Chenshuang Zhang ⁶¹ 2017	VEB 和 SVEB	四层 RNN, 前两层 LSTM, 后两层全连接层	MIT-BIH 数据库	VEB: Acc 99.7 Se 97.1 Sp 99.9 Pp 98.1 SVEB: Acc 99.3 Se 85.9 Sp 99.7 Pp 88.7
6	Mathews S M ⁶² 2018	心室和室上心率检测	深信度网络 (DBN)	MIT-BIH 数据库	平均识别率 95.57%
7	Ulas BaranBaloglu ⁶³ 2019	10 种心肌梗塞 (MI)	10 层 CNN	Physiobank (PTB) 数据包括 52 名正常人和 148 名心肌梗死患者的心电图记录。	Acc: 超过 99%
8	Bahareh Pourbabaee ⁶⁴ 2016	阵发性房颤 (PAF)	5 层 CNN,	PAF 预测挑战数据库	Acc: 91%
9	Andersen Rasmus S65 2018	心房颤动 (AF)	3 层 CNN 和双向 LSTM	MIT-BIH AF Database the MIT-BIH Arrhythmia Database the MIT-BIH NSR Database	Sen 和 Spe 分别为 98.98% 和 96.95%
10	OzalYildirim66 2018	心电图数据压缩	心电信号压缩的深卷积自编码 (CAE) 模型	MIT-BIH	模型的压缩率为 32.25, 平均 PRD 值为 2.73%。
11	Oliver F ⁶⁷ 2018	心房颤动 (AF)	LSTM	MIT-BIH	Acc: 99.77%。
12	Isin A ⁶⁸ 2017	正常、RBBB 和起搏搏动	AlexNet bp 神经网络	MIT-BIH	训练 Acc: 98.51%, 测试 Acc: 92%
13	G.Sannino ⁶⁹	正常和异常	深度神经网络	MIT-BIH 数据库	平均秩误差为 0.00%

	2018		(DNN)		
14	Ruggero Donida Labati ⁷⁰ 2019	基准、非基准和部分基准 ⁷¹	基于 CNN 的 Deep-ECG	PTB	Acc100%
15	Huanhuan M ⁷² 2014	N、LBBB、RBBB、房性早搏、室性早搏和起搏	深度信念网络	MIT-BIH	Acc98.49
16	Acharya U R ⁷³ 2018	充血性心力衰 (CHF)	11 层深 CNN 网络	PhysioBank MIT-BIH	Acc98.97% , Spe99.01% , Sen98.87%。
17	Shashikumar S P ⁷⁴ 2017	房颤 (AF)	CNN	埃默里大学医院(EUH) 埃默里大学中城医院(EUHM) 格雷迪纪念医院(GMH)	Acc 为 91.8%
18	Zhang Q ⁷⁵ 2017	心律失常, 心房纤颤和恶性心律失常	一维 CNN 网络 (1-D-CNN)	MIT-BIH	平均识别率达到 93.5%
19	Xia Y ⁷⁶ 2017	房颤	深 CNN 网络的二维矩阵输入。	MIT-BIH AFIB	Sen 为 98.79%, Spe 为 97.87% , Acc 为 98.63%。
20	Lih O S ⁷⁷ 2018	N、LBBB、RBBB、房性早搏、室性早搏	CNN 网络和 LSTM 网络	MIT-BIH 数据库	Acc98.10% , Sen 为 97.50% , Spe 为 98.70%。
21	Yildirim ⁷⁸ 2018	N、LBBB、RBBB、房性早搏、室性早搏	双向 LSTM DBLSTM-WS 模型	MIT-BIH 数据库	识别率高达 99.39%
22	Tan J H ⁷⁹ 2018	冠状动脉疾病 (CAD)	CNN 网络和 LSTM 网络	多个数据库 所开发的原型模型在临床使用前已准备好用适当的大型数据库进行测试。	Acc: 99.85%
23	Yildirim ⁸⁰ 2018	心律不齐 (17 类)	一维 CNN 网络模型 (1D-CNN)	MIT-BIH	识别率 91.33% ,
24	Acharya U R ⁸¹ 2017	五类, 即非异位、室上异位、室性异位、融合和未知心跳。	9 层深 CNN 网络	MIT-BIH	Acc: 原始心电图 94.03% 和无噪声心电图 93.47%。
25	U. Rajendra Acharya ⁸² 2017	心肌梗死 (MI)	CNN 网络	PTB Physikalisch-Technische Bundesanstalt	Acc: 有噪声 93.53% , 无噪声 95.22%
26	Acharya U R ⁸³ 2017	心房颤动、心房扑动和心室颤动	11 层深的 CNN	Creighton University MIT-BIH 心房颤动 MIT-BIH 心律失常数据库	5 秒心电图: Acc 94.90% , Sen 为 99.13% , Spe 为 81.44%。
27	M.M. Rahhal ⁸⁴ 2016	AAAMI 分类协议	稀疏约束的叠层去噪自编码器 (SDAEs) 深神经网络 (DNN)	MIT-BIH 心律失常数据库 INSTART SVDB	2s: Acc 92.50% , Sen98.09% , Spe93.13% 5s: Acc94.90% , Sen99.13% , Spe81.44%

28	Fujita H ⁸⁵ 2019	三种	6层深 CNN 网络	心律失常 PhysioBank 数据库、MIT-BIH 恶性室性心律失常数据库(Vfdb)、MIT-BIH 房颤数据库 (AfDB)、MIT-BIH 心律失常数据库(Mitdb)	2 秒心电图：Acc 97.78% ， Spe 为 98.82% ， Sen 为 99.76%。
29	Niu J ⁸⁶ 2019	室上性异位搏动 (SVEB) 和室上性异位搏动 (VEB)	多视角 CNN 网络 (MPCNN)	MIT-BIH	整体 Acc 为 96.4%，SVEB 和 VEB 的 F ₁ 分数分别为 76.6% 和 89.7%。
30	Yildirim O ⁸⁷ 2019	心律失常性	卷积自动编码 (CAE) 压缩，LSTM 分类	MIT-BIH	ECG 信号被平均 0.70% 的均方根差 (PRD) 率压缩，并且有超过 99.0% 的精确度
31	Ji J ⁸⁸ 2018	非持续性室性心动过(NsVT)、室上性心动过速 (SVT)、心房纤颤(AF)和心房扑动	深度参数共享网络	MIT-BIH	该方案能提高心电数据分析的准确率约 5.1%
32	Tripathy R K ⁸⁹ 2019	心肌梗死 (MI)	深层神经网络	Physikalisch Technische Bundesanstalt(PTB)	准确度 99.74%、Sen 99.87%、Spe99.60%。
33	Wu Z, Ding X ⁹⁰ 2016	N、LBBB、RBBB、房性早搏、室性早搏	深度信念网络	MIT-BIH 心律失常数据库	Acc: 99.5%
34	Mitrokhin M ⁹¹ 2017	无	两种不同的神经网络	physinet.org	QRS 波检测方法
35	Lo F W ⁹² 2018	无	二维 CNN 网络	PhysioNet	胎儿心电检测
36	Kachuee M ⁹³ 2018	AAMI 标准和心肌梗死	深 CNN 网络	MIT-BIH、PTB	Acc: 心律失常 93.4%，心肌梗死 95.9%。
37	DIKER A ⁹⁴ 2019	AAMI	CNN 网络	physynet	ELM 的分类成功率分别达到 88.33%、89.47% 和 87.80%。
38	Chen Y J ⁹⁵ 2019	6 种常见急性心律失常的分类模型。	CNN 网络和 LSTM 网络相结合	台北荣民总医院心内科, 12 导联数据集	平均 Acc 为 0.81%
39	Majumdar A ⁹⁶ 2017	基于 MIT-BIH	深度字典学习 RDDLL ₁ 范数代价函数	MIT-BIH 心律失常数据库	ACC : 97.0%
40	Nurmaini S ⁹⁷ 2019	10 类心电信号的不平衡数据	深度自动编码器 (DAEs) 和分类器形式的深度神经网络 (DNNs)	MIT-BIH	Acc : 99.73% ， Sen91.20% ， Spe99.80% ， F ₁ 评分 91.80%
41	Yoon D ⁹⁸ 2019	可接受和不可接受	提出了一种基于 CNN 网络的不可接受心电图筛查模型	创伤重症监护室	F ₁ 分数：0.93 和 0.80 (Sen0.88 ， Spe0.89 ， 阳性预测值 0.74， 阴性预测值 0.96)。
42	Ji Y ⁹⁹	五种	CNN 网络 (faster	MIT-BIH	平均 Acc:99.21%

	2019		R-CNN)		
43	Picon A ¹⁰⁰ 2019	心室颤动 (VF)	一维 CNN 层和 LSTM 网络	Holter 数据库, OHCA 患者	4sECG : BAC : 99.3%、S : 99.7%、Sp: 98.9%, OHCA 分别为 98.0%、99.2%、96.7%。
44	Maya S ¹⁰¹ 2019	异常心电检测	延迟长短期存储器 (dLSTM)	PhysioBank	中位值小于 4
45	Ince T ¹⁰² 2017	AAMI	CNN 网络	MIT-BIH	最高 Acc: 99%
46	Yuan B ¹⁰³ 2019	8 种心脏异常	CNN 网络	中国 ECG 智能竞赛, 12 导联	F ₁ 分数: 0.797
47	Sayantan G ¹⁰⁴ 2018	SVEB、VEB	DBN	MIT-BIH、SVDB	Acc: SVEB 99.5%、VEB 99.4%
48	Sbrollini A ¹⁰⁵ 2019	13 种心脏异常	深度学习神经网络 (NNS) 3 层神经网络结构	两个临床心电数据库 已知临床稳定状态的患者的 ECG 数据库	Acc 为 84% 和 83%
49	Venkatesan C ¹⁰⁶ 2018	正常和异常	自适应滤波器,	MIT-BIH	Acc: 97.5%
50	Ebrahimzadeh E ¹⁰⁷ 2018	心脏性猝死 (SCD)	两类是用多层感知器 (MLP) 分类器分类的	MIT-BIH	平均 Acc: 88.29%

参考文献

- 1 Farabet C, Couprie C, Najman L, et al. Learning hierarchical features for scene labeling. *IEEE Trans Pattern Anal Mach Intell*, 2013;35(8):1915–29.
- 2 Liu N, Han J, Zhang D, et al. Predicting eye fixations using convolutional neural networks. In: *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*. 2015. p.362–70.
- 3 Hinton G, Deng L, Yu D, et al. Deep neural networks for acoustic modeling in speech recognition: the shared views of four research groups. *IEEE Signal Process Mag* 2012;29(6):82–97.
- 4 Sainath TN, Mohamed A-R, Kingsbury B, et al. Deep convolutional neural networks for LVCSR. In: *2013 IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP)*, 2013. p. 8614–8. IEEE, New York.
- 5 Kiros R, Zhu Y, Salakhutdinov RR, et al. Skip-thought vectors. In: *Advances in Neural Information Processing Systems*. 2015, p.3276–84.
- 6 Li J, Luong M-T, Jurafsky D. A hierarchical neural autoencoder for paragraphs and documents. *arXiv Preprint arXiv:1506.01057*, 2015.
- 7 Luong M-T, Pham H, Manning CD. Effective approaches to attention-based neural machine translation. *arXiv Preprint arXiv:1508.04025*, 2015.
- 8 Cho K, Van Merriënboer B, Gulcehre C, et al. Learning phrase representations using RNN encoder–decoder for statistical machine translation. *arXiv Preprint arXiv:1406.1078*, 2014.
- 9 D. Ravi et al., “Deep learning for health informatics,” *IEEE J. Biomed. Health Inform.*, vol. 21, no. 1, pp. 4–21, Jan. 2017.
- 10 P. Mamoshina, A. Vieira, E. Putin, and A. Zhavoronkov, Applications of deep learning in biomedicine, *Mol. Pharmaceutics*, vol. 13, no. 5, pp. 1445–1454, 2016.

-
- 11 S. Min, B. Lee, and S. Yoon, Deep learning in bioinformatics, *Brief Bioinform.*, vol. 18, no. 5, pp. 851–869, 2016.
- 12 Illustration from Anatomy & Physiology, Connexions Web Site, 2013 <http://cnx.org/content/col11496/1.6/>.
- 13 Heart Rhythm Society, Heart diseases and disorders, 2017. [Online]. Available:<http://www.hrsonline.org/Patient-Resources/Heart-Diseases-Disorders>. [Accessed: 05-Jul-2017].
- 14 Benjamin EJ, et al. Heart Disease and Stroke Statistics-2019 Update: A Report From the American Heart Association. *Circulation*, Originally published, 31 Jan 2019.
- 15 National Heart Lung and Blood Institute, "Types of arrhythmias," 2011. [Online]. Available: <https://www.nhlbi.nih.gov/health/health-topics/topics/arr/types>. [Accessed: 05-Jul-2017].
- 16 U. R. Acharya, J. S. Suri, J. A. E. Spaan, and S. M. Krishnan, *Advances in cardiac signal processing*. 2007.
- 17 Yuzhen, C.; Zengfei, F. Feature search algorithm based on maximum divergence for heart rate classification. *J. Biomed. Eng.* 2008, 25, 53–56.
- 18 Ceylan, R.; Zbay, Y. Comparison of FCM, PCA and WT techniques for classification ECG arrhythmias using artificial neural network. *Expert Syst. Appl.* 2007, 33, 286–295. [CrossRef]
- 19 Beyli, E.D. Combining recurrent neural networks with eigenvector methods for classification of ECG beats. *Digit. Signal Process.* 2009, 19, 320–329.
- 20 Park, J.; Lee, K.; Kang, K. Arrhythmia detection from heartbeat using k-nearest neighbor classifier. In *Proceedings of the IEEE International Conference on Bioinformatics and Biomedicine, Shanghai, China, 18–21 December 2013*; pp. 15–22.
- 21 Kiranyaz, S.; Ince, T.; Gabbouj, M. Real-time patient-specific ECG classification by 1-D convolutional neural networks. *IEEE Trans. Biomed. Eng.* 2016, 63, 664–675. [CrossRef]
- 22 Rajpurkar, P.; Hannun, A.Y.; Haghpanahi, M.; Bourn, C.; Ng, A.Y. Cardiologist-level arrhythmia detection with convolutional neural networks. *arXiv* 2017, arXiv:1707.01836.
- 23 Yıldırım, Ö.; Pławiak, P.; Tan, R.S.; Acharyae, U.R. Arrhythmia detection using deep convolutional neural network with long duration ECG signals. *Comput. Biol. Med.* 2018, 102, 411–420. [CrossRef] [PubMed]
- 24 Acharya, U.R.; Oh, S.L.; Hagiwara, Y.; Tan, J.H.; Adam, M.; Gertych, A.; Tan, R.S. A Deep Convolutional Neural Network Model to Classify Heartbeats. *Comput. Biol. Med.* 2017, 89, 389–396. [CrossRef] [PubMed]
- 25 Acharya, U.R.; Fujita, H.; Sudarshan, V.K.; Oh, S.L.; Adam, M.; Koh, J.E.W. Automated detection and localization of myocardial infarction using electrocardiogram: A comparative study of different leads. *Knowl.-Based Syst.* 2016, 99, 146–156. [CrossRef]
- 26 Hwang, B.; You, J.; Vaessen, T.; Myin-Germeys, I.; Park, C.; Zhang, B.T. Deep ECGNet: An Optimal Deep Learning Framework for Monitoring Mental Stress Using Ultra Short-Term ECG Signals. *Telemed J. E Health* 2018, 24, 753–772. [CrossRef] [PubMed]
- 27 *心电图学*, 郭继鸿主编, 人民卫生出版社, 2005.
- 28 G. Y. Lip, C. M. Brechin, and D. A. Lane, The global burden of atrial fibrillation and stroke: a systematic review of the epidemiology of atrial fibrillation in regions outside north america and europe, *CHEST Journal*, vol. 142, no. 6, pp. 1489–1498, 2012.
- 29 S. Prabhakar, S. Pankanti, and A. K. Jain, Biometric recognition: Security and privacy concerns, *IEEE Security Privacy*, vol. 1, no. 2, pp. 33–42, Mar. 2003.
- 30 Berkaya S K , Uysal A K , Gunal E S , et al. A survey on ECG analysis[J]. *Biomedical Signal Processing and Control*, 2018, 43:216-235.

-
- 31 K. Minami, H. Nakajima, and T. Toyoshima, Real-time discrimination of ventricular tachyarrhythmia with Fourier-transform neural network, *IEEE Trans. Biomed. Eng.*, vol. 46, no. 2, pp. 179–185, Feb. 1999.
- 32 S. Kiranyaz, T. Ince, J. Pulkkinen, and M. Gabbouj, Personalized long-term ECG classification: A systematic approach, *Expert Syst. Appl.*, vol. 38, no. 4, pp. 3220–3226, Apr. 2011.
- 33 Y. H. Hu, S. Palreddy, and W. J. Tompkins, A patient-adaptable ECG beat classifier using a mixture of experts approach, *IEEE Trans. Biomed. Eng.*, vol. 44, no. 9, pp. 891–900, Sep. 1997.
- 34 J. Fayn, A classification tree approach for cardiac ischemia detection using spatiotemporal information from three standard ECG leads, *IEEE Trans. Biomed. Eng.*, vol. 58, no. 1, pp. 95–102, Jan. 2011.
- 35 L. Pecchia, P. Melillo, and M. Bracale, Remote health monitoring of heart failure with data mining via CART method on HRV features, *IEEE Trans. Biomed. Eng.*, vol. 58, no. 3, pp. 800–804, Mar. 2011.
- 36 Y. H. Hu, W. J. Tompkins, J. L. Urrusti, and V. X. Afonso, Applications of artificial neural networks for ECG signal detection and classification, *J. Electrocardiol.*, vol. 26, pp. 66–73, Jan. 1993.
- 37 D. A. Coast, R. M. Stern, G. G. Cano, and S. A. Briller, An approach to cardiac arrhythmia analysis using hidden Markov models, *IEEE Trans. Biomed. Eng.*, vol. 37, no. 9, pp. 826–836, Sep. 1990.
- 38 S. Osowski, T. Hoai, and T. Markiewicz, Support vector machine-based expert system for reliable heartbeat recognition, *IEEE Trans. Biomed. Eng.*, vol. 51, no. 4, pp. 582–589, Apr. 2004.
- 39 J.-S. Wang, W.-C. Chiang, Y.-L. Hsu, and T.-C. Yang, ECG rhythm classification using a probabilistic neural network with a feature reduction method, *Neurocomputing*, vol. 116, pp. 38–45, Sep. 2013.
- 40 E. D. Ibeyli, Recurrent neural networks employing Lyapunov exponents for analysis of ECG signals, *Expert Syst. Appl.*, vol. 37, no. 2, pp. 1192–1199, Mar. 2010.
- 41 E. J. da S. Luz, T. M. Nunes, V. H. C. De Albuquerque, J. P. Papa, and D. Menotti, ECG arrhythmia classification based on optimum-path forest, *Expert Syst. Appl.*, vol. 40, no. 9, pp. 3561–3573, Jul. 2013.
- 42 Goodfellow, I., Bengio, Y., Courville, A. *Deep learning* (Vol. 1). Cambridge: MIT press, 2016
- 43 Gu, J., Wang, Z., Kuen, J., Ma, L., Shahroudy, A., Shuai, B., Liu, T., Wang, X., Wang, L., Wang, G. and Cai, J., 2015. Recent advances in convolutional neural networks. *arXiv preprint arXiv:1512.07108*.
- 44 Hochreiter, S., Schmidhuber, J., Long Short-Term Memory” , *Neural Computation* 9 (8), 1997, pp. 1735–1780
- 45 Nesterov, 1983) (Nesterov, Y. (1983). A method of solving a convex programming problem with convergence rate $O(1/k^2)$. *Soviet Mathematics Doklady*, 27 (2), 372–376 .
- 46 Hinton, Geoffrey, Simon Osindero, and Yee-Whye The, A fast learning algorithm for deep belief nets, *Neural computation* 2006. 18(7), pp.1527-1554.
- 47 Hinton, Geoffrey E., and Ruslan R. Salakhutdinov, Reducing the dimensionality of data with neural networks, *Science*, 2006.313(5786), pp.504-507.
- 48 W. Jiang and S. G. Kong, “Block-based neural networks for personalized ECG signal classification” , *IEEE Trans. Neural Netw.*, vol. 18, no. 6, pp. 1750–1761, Nov. 2007.
- 49 T. Ince, S. Kiranyaz, and M. Gabbouj, A generic and robust system for automated patient-specific classification of ECG signals, *IEEE Trans. Biomed. Eng.*, vol. 56, no. 5, pp. 1415–1426, May 2009.
- 50 S. Kiranyaz, T. Ince, and M. Gabbouj, Real-time patient-specific ECG classification by 1-D convolutional neural networks, *IEEE Trans. Biomed. Eng.*, vol. 63, no. 3, pp. 664–675, Mar. 2016.
- 51 M.A. Awal, S.S. Mostafa, M. Ahmad, et al., An adaptive level dependent wavelet thresholding for ECG denoising, *Biocybern. Biomed. Eng.* 34 (4) (2014)238–249.

-
- 52 G.U. Reddy, M. Muralidhar, S. Varadarajan, ECG de-noising using improved thresholding based on wavelet transforms, *Int. J. Comput. Sci. Netw. Secur.* 9 (9) (2009) 221–225.
- 53 V. Afonso, W. Tompkins, T. Nguyen, S. Trautmann, S. Luo, Filter bank-based processing of the stress ECG, in: *Proceedings of the IEEE 17th Annual Conference on Engineering in Medicine and Biology Society*, 1995, pp. 887–888.
- 54 Wang J, Li R, Li R, et al. Adversarial De-noising of Electrocardiogram[J]. *Neurocomputing*, 2019.
- 55 J.Pan,W.J.Tompkins,Areal-timeQRSdetectionalgorithm,IEEETrans.Biomed.Eng. (3) (1985) 230–236.
- 56 P.Laguna,Newelectrocardiographicsignalprocessingtechniques:Application to long-term records, (Ph.D. Thesis), Science Faculty, University of Zaragoza,1990.
- 57 Shalin S , Vahid E . Cardiac Arrhythmia Classification by Multi-Layer Perceptron and Convolution Neural Networks[J]. *Bioengineering*, 2018, 5(2):35-.
- 58 Xia Y , Gao Z , Zhang H , et al. An automatic cardiac arrhythmia classification system with wearable electrocardiogram[J]. *IEEE Access*, 2018:1-1.
- 59 Ribas Ripoll V J , Wojdel A , Romero E , et al. ECG assessment based on neural networks with pretraining[J]. *Applied Soft Computing*, 2016:S1568494616304070.
- 60 Xiong Z , Stiles M K , Zhao J . Robust ECG signal classification for detection of atrial fibrillation using a novel neural network[C]// 2017 Computing in Cardiology (CinC). IEEE, 2018.
- 61 Zhang C , Wang G , Zhao J , et al. [ACTAPRESS Biomedical Engineering - Innsbruck, Austria (2/20/2017-2/21/2017)] Biomedical Engineering - Patient-Specific ECG Classification Based on Recurrent Neural Networks and Clustering Technique[J]. 2017.
- 62 Mathews S M , Chandra K , Barner K E . A novel application of deep learning for single-lead ECG classification[J]. *Computers in Biology and Medicine*, 2018, 99:53-62.
- 63 Ulas Baran Baloglua, Muhammed Talo. Classification of myocardial infarction with multi-lead ECG signals and deep CNN[J]. *Pattern Recognition Letters*,2019, 122: 23-30.
- 64 Pourbabaee B , Roshtkhari M J , Khorasani K . Feature leaning with deep Convolutional Neural Networks for screening patients with paroxysmal atrial fibrillation[C]// International Joint Conference on Neural Networks. IEEE, 2016.
- 65 Andersen R S , Abdolrahman P , Sadasivan P . A Deep Learning Approach for Real-Time Detection of Atrial Fibrillation[J]. *Expert Systems with Applications*, 2018:S0957417418305190-.
- 66 Ozal Yildirim,Ru SanTan,U. Rajendra Acharya. An efficient compression of ECG signals using deep convolutional autoencoders[J], *Cognitive Systems Research*,2018,52: 198-211.
- 67 Oliver F , Alex S , Murtadha K , et al. Automated detection of atrial fibrillation using long short-term memory network with RR interval signals[J]. *Computers in Biology and Medicine*, 2018:S0010482518301847-.
- 68 Isin A , Ozdalili S . Cardiac arrhythmia detection using deep learning[J]. *Procedia Computer Science*, 2017, 120:268-275.
- 69 G.Sannino,G.De Pietro.A deep learning approach for ECG-based heartbeat classification for arrhythmia detection[J], *Future Generation Computer Systems*, 2018, 86:446-45.
- 70 Ruggero Donida Labati, Enrique Muñoz.Deep-ECG: Convolutional Neural Networks for ECG biometric recognition[J], *Pattern Recognition Letters*,2019,126:78-85
- 71 I. Odínaka , P.-H. Lai , A. Kaplan , J. O' Sullivan , E. Sirevaag , J. Rohrbaugh , ECG Bio- metric recognition: a comparative analysis, *IEEE Trans. Inf. Forensics Secur.* 7 (6) (2012) 1812–1824 .
- 72 Huanhuan M , Yue Z . Classification of Electrocardiogram Signals with Deep Belief Networks[C]// 2014 IEEE 17th International Conference on Computational Science and Engineering (CSE). IEEE, 2014.

-
- 73 Acharya U R , Fujita H , Oh S L , et al. Deep convolutional neural network for the automated diagnosis of congestive heart failure using ECG signals[J]. Applied Intelligence, 2018.
- 74 Shashikumar S P , Shah A J , Li Q , et al. A deep learning approach to monitoring and detecting atrial fibrillation using wearable technology[C]// IEEE Embs International Conference on Biomedical & Health Informatics. IEEE, 2017.
- 75 Zhang Q , Zhou D , Zeng X . HeartID: A Multiresolution Convolutional Neural Network for ECG-based Biometric Human Identification in Smart Health Applications[J]. IEEE Access, 2017:1-1.
- 76 Xia Y , Wulan N , Wang K , et al. Detecting atrial fibrillation by deep convolutional neural networks[J]. Computers in Biology and Medicine, 2017:S0010482517304043.
- 77 Lih O S , Ng E Y K , San T R , et al. Automated diagnosis of arrhythmia using combination of CNN and LSTM techniques with variable length heart beats[J]. Computers in Biology and Medicine, 2018:S0010482518301446-.
- 78 Yildirim, ?zal. A novel wavelet sequences based on deep bidirectional LSTM network model for ECG signal classification[J]. Computers in Biology and Medicine, 2018:S0010482518300738.
- 79 Tan J H , Hagiwara Y , Pang W , et al. Application of stacked convolutional and long short-term memory network for accurate identification of CAD ECG signals[J]. Computers in Biology and Medicine, 2018:S0010482517304201.
- 80 Yildirim, Özal, Pławiak, Paweł, Tan R S , et al. Arrhythmia detection using deep convolutional neural network with long duration ECG signals[J]. Computers in Biology and Medicine, 2018.
- 81 Acharya U R , Oh S L , Hagiwara Y , et al. A Deep Convolutional Neural Network Model to Classify Heartbeats[J]. Computers in Biology and Medicine, 2017, 89.
- 82 U. Rajendra Acharya, Hamido Fujita, Shu Lih Oh, Yuki Hagiwara, Jen Hong Tan, Muhammad Adam Application of deep convolutional neural network for automated detection of myocardial infarction using ECG signals[J]. Information Sciences, 2017, 415-416:190-198.
- 83 Acharya U R , Fujita H , Lih O S , et al. Automated detection of arrhythmias using different intervals of tachycardia ECG segments with convolutional neural network[J]. Information Sciences, 2017, 405:81-90.
- 84 M.M. Al Rahhal, Yakoub Bazi, Haikel AlHichri, Naif Alajlan, Farid Melgani, R.R. Yager, Deep learning approach for active classification of electrocardiogram signals[J], Information Sciences, 2016, 345:340-354.
- 85 Fujita H , Cimr D . Decision support system for arrhythmia prediction using convolutional neural network structure without preprocessing[J]. Applied Intelligence, 2019.
- 86 Niu J , Tang Y , Sun Z , et al. Inter-Patient ECG Classification with Symbolic Representations and Multi-Perspective Convolutional Neural Networks[J]. IEEE journal of biomedical and health informatics, 2019.
- 87 Yildirim O , Baloglu U B , Tan R S , et al. A new approach for arrhythmia classification using deep coded features and LSTM networks[J]. Computer methods and programs in biomedicine, 2019, 176: 121-133.
- 88 Ji J , Chen X , Luo C , et al. A deep multi-task learning approach for ECG data analysis[C]//2018 IEEE EMBS International Conference on Biomedical & Health Informatics (BHI). IEEE, 2018: 124-127.
- 89 Tripathy R K , Bhattacharyya A , Pachori R B . A novel approach for detection of myocardial infarction from ECG signals of multiple electrodes[J]. IEEE Sensors Journal, 2019, 19(12): 4509-4517.
- 90 Wu Z , Ding X , Zhang G , et al. A novel features learning method for ECG arrhythmias using deep belief networks[C]//2016 6th International Conference on Digital Home (ICDH). IEEE, 2016: 192-196.
- 91 Mitrokhin M , Kuzmin A , Mitrokhina N , et al. Deep Learning Approach for QRS Wave Detection in ECG Monitoring[C]//2017 IEEE 11th International Conference on Application of Information and Communication Technologies (AICT). IEEE, 2017: 1-3.

-
- 92 Lo F W, Tsai P Y. Deep Learning for Detection of Fetal ECG from Multi-Channel Abdominal Leads[C]//2018 Asia-Pacific Signal and Information Processing Association Annual Summit and Conference (APSIPA ASC). IEEE, 2018: 1397-1401.
- 93 Kachuee M, Fazeli S, Sarrafzadeh M. Ecg heartbeat classification: A deep transferable representation[C]//2018 IEEE International Conference on Healthcare Informatics (ICHI). IEEE, 2018: 443-444.
- 94 DIKER A, Engin A. Feature Extraction of ECG Signal by using Deep Feature[C]//2019 7th International Symposium on Digital Forensics and Security (ISDFS). IEEE, 2019: 1-6.
- 95 Chen Y J, Liu C L, Tseng V S, et al. Large-scale Classification of 12-lead ECG with Deep Learning[C]//2019 IEEE EMBS International Conference on Biomedical & Health Informatics (BHI). IEEE, 2019: 1-4.
- 96 Majumdar A, Ward R. Robust greedy deep dictionary learning for ECG arrhythmia classification[C]//2017 International Joint Conference on Neural Networks (IJCNN). IEEE, 2017: 4400-4407.
- 97 Nurmaini S, Umi Partan R, Caesarendra W, et al. An Automated ECG Beat Classification System Using Deep Neural Networks with an Unsupervised Feature Extraction Technique[J]. Applied Sciences, 2019, 9(14): 2921.
- 98 Yoon D, Lim H S, Jung K, et al. Deep Learning-Based Electrocardiogram Signal Noise Detection and Screening Model[J]. Healthcare Informatics Research, 2019, 25(3): 201-211.
- 99 Ji Y, Zhang S, Xiao W. Electrocardiogram Classification Based on Faster Regions with Convolutional Neural Network[J]. Sensors, 2019, 19(11): 2558.
- 100 Picon A, Irusta U, Álvarez-Gila A, et al. Mixed convolutional and long short-term memory network for the detection of lethal ventricular arrhythmia[J]. PloS one, 2019, 14(5): e0216756.
- 101 Maya S, Ueno K, Nishikawa T. dLSTM: a new approach for anomaly detection using deep learning with delayed prediction[J]. International Journal of Data Science and Analytics, 2019: 1-28.
- 102 Ince T, Zabihi M, Kiranyaz S, et al. Learned vs. Hand-Designed Features for ECG Beat Classification: A Comprehensive Study[M]//EMBECC & NBC 2017. Springer, Singapore, 2017: 551-554.
- 103 Yuan B, Xing W. Diagnosing Cardiac Abnormalities from 12-Lead Electrocardiograms Using Enhanced Deep Convolutional Neural Networks[M]//Machine Learning and Medical Engineering for Cardiovascular Health and Intravascular Imaging and Computer Assisted Stenting. Springer, Cham, 2019: 36-44.
- 104 Sayantan G, Kien P T, Kadambari K V. Classification of ECG beats using deep belief network and active learning[J]. Medical & Biological Engineering & Computing, 2018, 56(10): 1887-1898.
- 105 Sbröllini A, De Jongh M C, Ter Haar C C, et al. Serial electrocardiography to detect newly emerging or aggravating cardiac pathology: a deep-learning approach[J]. Biomedical engineering online, 2019, 18(1): 15.
- 106 Venkatesan C, Karthigaikumar P, Varatharajan R. A novel LMS algorithm for ECG signal preprocessing and KNN classifier based abnormality detection[J]. Multimedia Tools and Applications, 2018, 77(8): 10365-10374.
- 107 Ebrahimzadeh E, Manuchehri M S, Amoozegar S, et al. A time local subset feature selection for prediction of sudden cardiac death from ECG signal[J]. Medical & biological engineering & computing, 2018, 56(7): 1253-1270.