用于雷达和通信信号分类的LSTM框架

Victoria Clerico* （IEEE学生会员）、Jorge Gonz´alez-L´opez*、
Gady Agam†、Jes´ús Grajal* （IEEE高级会员）

*马德里理工大学信息处理与电信中心，电信工程高等技术学院，Av. Complutense 30，
28040 马德里，西班牙。通讯作者：Victoria Clerico（电子邮件：mclerico@ieee.org）

†伊利诺伊理工学院计算机科学系，美国芝加哥

arXiv:2305.03192v2 [eess.SP] 9 Jan 2025

摘要——**尽管雷达信号和通信信号的分类通常被分别处理，但二者具有相似的特征，因此，一个领域中采用的方法也有可能应用于另一个领域。我们提出一种简单统一的方案，利用长短期记忆（LSTM）神经网络对雷达信号和通信信号进行分类。对于雷达信号领域，这项方案提升了最先进水平；目前，LSTM模型正开始应用于复杂度更高的方案中。迄今为止，还没有面向雷达信号的标准公共数据集。因此，我们提出DeepRadar2022[1]，雷达数据集，并在系统评估中使用该数据集。该数据集已公开发布，有助于实现不同方法之间的标准化比较。**

索引词——**通信信号、雷达信号、自动调制分类器、神经网络、长短期记忆网络。**

I. 引言

自动调制分类（AMC）是指自动确定一系列采集样本的调制方式。它是信号检测之后的步骤，也是数据解调所必需的，因此在许多民用和军用接收机中发挥着重要作用[1]。

考虑到经典方法，AMC算法可分为两类：基于似然函数的方法（LB，即“基于似然”）和基于特征提取的方法（FB，即“基于特征”） [2]。前者通过假设概率密度函数（PDF）包含特定波形所需的全部信息，尽可能降低误分类概率，从而提供最优解。因此，分类时会将PDF似然比与判决阈值进行比较[2]。其问题在于计算复杂度较高，因此不适用于实际工作环境。相比之下，FB算法会提取各类信号的代表性特征，以供后续分类使用。这类算法虽然不是最优的，但通常因易于实现且适用于实时应用而更受青睐 [2]。尽管如此，FB分类器仍然依赖大量专家知识。因此，尽管这类方法在特定环境中能够很好地近似实现，但其复杂度很高，且开发耗时较长。虽然这些算法已成功用于开发AMC，但机器学习（ML）和深度学习（DL）被认为是开发高性能、高精度AMC的良好替代方案，无需采用耗时的经典方法。近来，K近邻[3]，支持向量机 [3], [4]，多层感知机（MLP） [5],循环神经网络（RNN） [6], [7] 和卷积神经网络（CNN） [8]–[11] 等算法已被用于此目的。

以往文献表明，长短期记忆网络在序列处理与分类方面表现出色。因此，我们旨在提出一种基于长短期记忆网络的稳健且简化的自动调制分类方法，用于通信信号和雷达信号。为此，我们使用了公开的 RadioML 2018.01A 通信数据集 [9]。由于没有公开的雷达信号数据集，我们创建并发布了 DeepRadar2022[1]，，这是一个包含 23 个类别的连续波和脉冲信号雷达数据集。此外，为了进行比较，我们复现了一个包含八种雷达信号类型的数据集，该数据集由当前雷达信号分类领域的最新文献提出 [7]。

本文其余部分安排如下：第 II 节概述了与基于深度学习和机器学习的自动调制分类相关的主要研究与方案。第 III 节介绍信号模型和数据集。随后，第 IV 节阐述我们的神经网络架构、评估指标和实验，第 V 节呈现实验结果。最后，第 VI 节总结本文的主要结论。

II. 相关工作

尽管 LB 和 FB 分类算法颇具实用价值，人工智能的出现仍彻底改变了许多重要领域。过去，机器学习和深度学习工具曾被用于构建通信信号和雷达信号的调制分类器，但二者一直被分别处理。

在通信信号分类中，最典型的信号表示形式是时间序列，而应用最广泛的是
用于对其进行分类的方法是一维卷积神经网络

本研究由 MCIN/AEI/10.13039/501100011033 资助的项目 PID2020-113979RB-C21 提供支持。

[1]可在 https://www.kaggle.com/datasets/khilian/deepradar 下载

[8], [12]–[21]。类似地，近期提出的 GGCNN[22] 和 SE-MSFN [23] 使用 RadioML2018.01A，取得了更优的结果。

相比之下，雷达信号的分类方法包括通过特征提取和某些多层感知机架构 [5] 进行分类，或将记录的信号作为时频图像，结合二维卷积神经网络 [3]–[5], [24] 进行分类；也包括混合卷积神经网络与基于树结构的机器学习流程优化分类器 [25], 、结合强化学习的卷积神经网络 [26], 、结合去噪自编码器的卷积神经网络 [11], [27], [28] 以及结合长短期记忆网络的卷积神经网络 [29], [30]。近年来用于雷达分类的一些基于卷积神经网络的预训练模型包括 AlexNet [10] 和 Inception [11]。此外，近年来也有一些尝试通过将信号作为时间序列进行处理来使用循环神经网络，其中一些采用了结合注意力机制的长短期记忆网络 [7] 或门控循环单元网络 [31]–[33]。

III. 信号模型与数据集

为了开展实验，应选择一个或多个数据源，并确保每个类别包含大量信号。

A. 信号模型

这些数据集由雷达信号或通信信号组成。这些信号由以下模型定义：

$$s(t) = As_n(t) + r(t) \tag{1}$$

其中， $s_n(t)$ 表示单位功率的归一化信号， A对应信号功率的缩放因子， $r(t)$ 是复加性高斯噪声（CAWN），其实部和虚部的方差均为 σ^2。因此，所得信噪比如下所示。

$$snr = \frac{A^2}{2\sigma^2} \tag{2}$$

所有信号的尺寸均为 1024x2，对应时间采样的同相与正交分量。由于我们的 LSTM 框架具有固定的输入尺寸，因此需要大小相同的信号数据集来处理这些序列。下面介绍实验中使用的三个数据集。

B. 数据集

- 通信信号：这些信号来自 RadioML 2018.01A数据集[1]。该数据集包含 2555904 个信号，信噪比范围为 -20 dB 至 30 dB，步长为 2 dB。数据集中包含 24 种不同的数字和模拟调制：OOK、4-8 ASK、2-32 PSK、16-128 幅相移键控、16-256 QAM、带载波单边带调幅、AM- SSB-SC、带载波双边带调幅、AM-DSB-SC、调频、高斯最小频移键控和偏移四相相移键控。除了使用 GNU Radio 生成的带有合成信道效应的信号外，数据集还包含空中（OTA）录音 [9]。其主要局限在于，既未说明信号生成参数，也未说明每个信号的来源，即合成录音还是 OTA采集。
- 雷达信号：我们创建了**DeepRadar2022**，这是一个雷达信号时序数据集，涵盖表I中列出的23种调制方式及其所有参数：采样频率（f_s）、载波频率（f_c）、脉冲宽度（PW）、带宽（BW）、符号率（v_s）、巴克码长度（L_c）、单相位符号中的载波周期数（M）、M 的相对素数（r）、旁瓣幅度（S）、分段数（N_g）、相位状态（PS）和频率变化（Δf）。请注意， f_s 和输入序列分别固定为 100 MHz 和 1024 个样本。不过，符号数较少且符号率较高的调制方式会产生时间较短的信号，因此样本数也较少。因此，我们进行插值，以获得一组大小相同的信号。最后，我们为训练集创建了 469200 个信号，为验证集和测试集分别创建了 156400 个信号。因此，整个数据集包含 782000 个信号。

表I DeepRadar2022数据集调制方式及其相应参数汇总。

调制类型	参数	值
	f_s	100 MHz
	输入大小	1024 个样本
	SNR	-12:2:20 dB
	f_c	U(-f_s/4, f_s/4)
NM	-	-
LFM	BW	U(f_s/20, f_s/4)
PSK	阶数	{2,4,8}
	v_s	{2, 5, 10, 15, 20}
巴克码	L_c	{5,7,11,13}
	v_s	{2, 5, 10, 15, 20}
Frank ，P1, Px	M	{4, 5, 6, 7, 8}
	v_s	{7, 10, 15, 20}
P2	M	{4, 6, 8}
	v_s	{7, 10, 15, 20}
P3、P4	M	{16, 25, 36, 49, 64}
	v_s	{7, 10, 15, 20}
扎多夫-楚	M	{16, 25, 36, 49, 64}
	r	{11, 13}
	v_s	{7, 10, 15, 20}
霍夫曼	M	{16, 25, 36, 49, 64}
	v_s	{7, 10, 15, 20}
	S	{-63、-60、-56} dB
T1-T2	N_g	{4, 5, 6}
	PW	U(256, 1024) 个样本
	PS	2
T3-T4	BW	U(f_s/20, f_s/4)
	PW	U(256,1024) 个样本
	PS	2
FSK	阶数	{2,4,8}
	v_s	{1, 2, 5, 10, 15}
	Δf	v_s
科斯塔斯	M	{3,4,5,6}
	v_s	{1, 2, 5, 10, 15}
	Δf	v_s
噪声 (CAWN)	σ	1

v_s 数值以兆符号每秒为单位。 M 数值以符号为单位。U(.) 表示均匀随机分布。

此外，我们重新创建了八类信号数据集 pro-

[1]可在 www.deepsig.ai/datasets 下载

由 SABLNet [7] 的作者提出。这些信号的信噪比介于 -20 至 20 dB 之间，步长为 2 dB。按照其规范，生成的信号采用连续波、线性调频、二进制频移键控、正弦波、指数调制、锯齿波、二进制相移键控和二进制振幅键控调制。此外，作者提出了两种输入格式的信号分类：原始时序，以及经过自相关计算预处理后的信号。

IV. 长短期记忆框架

近年来，人们开始采用循环神经网络。循环神经网络源于一种尝试，旨在弥补卷积网络缺乏记忆能力的问题。它们并不将输入数据作为整体进行处理，而是依次遍历序列中的各个元素，并保留与所有先前元素有关的信息。然而，循环神经网络的主要问题是梯度消失，因为输入序列可能非常长。LSTM网络解决了尤为棘手的梯度消失问题。它们由四种不同的门单元（图1）和两种不同的记忆状态组成：长期记忆状态（记忆单元，$c^{<t>}$）和短期记忆状态（激活值，$a^{<t>}$）。通过这种方式，它们在保留重要信息的同时丢弃无价值的信息，从而应对梯度消失问题 [34]。正是这一特点，使LSTM网络在处理作为采样时间序列的信号时，非常适合用于我们的分类问题。

图1展示了构成长短期记忆层的各个单元的内部工作原理。这些单元采用了更复杂的结构，其中包括遗忘（$f^{<t>}$）、更新（$i^{<t>}$）和输出（$o^{<t>}$）参数，以及一个额外的、用于输出激活值的部分，即记忆单元（$c^{<t>}$）。每个门都执行以下方程：

$$\tilde{c}^{<t>} = \tanh(W_c \cdot [a^{<t-1>}, x^{<t>}] + b_c) \quad (3)$$

$$f^{<t>} = \text{sigmoid}(W_u \cdot [a^{<t-1>}, x^{<t>}] + b_u) \quad (4)$$

$$i^{<t>} = \text{sigmoid}(W_f \cdot [a^{<t-1>}, x^{<t>}] + b_f) \quad (5)$$

$$o^{<t>} = \text{sigmoid}(W_o \cdot [a^{<t-1>}, x^{<t>}] + b_o) \quad (6)$$

$$c^{<t>} = f^{<t>} * \tilde{c}^{<t>} + i^{<t>} * c^{<t-1>} \quad (7)$$

$$a^{<t>} = o^{<t>} * \tanh(c^{<t>}) \quad (8)$$

其中，W_c、W_u、W_f和 W_o 表示参数矩阵；b_c、b_u、b_f 和 b_o 表示偏置；$a^{<t>}$、$x^{<t>}$和 $c^{<t>}$分别表示时间戳 t 处的激活值、输入值和记忆单元值。

基于长短期记忆网络适合处理序列这一理念，我们提出的方案采用长短期记忆循环神经网络来处理信号的时间序列。简化后的网络仅由三个堆叠的长短期记忆层组成，每层包含 128 个单元，之后连接输出层。前两个长短期记忆层返回序列中的所有值（1024x128），最后一层则仅针对整个序列和每个记忆单元返回单个值（1x128）。最后，分类层

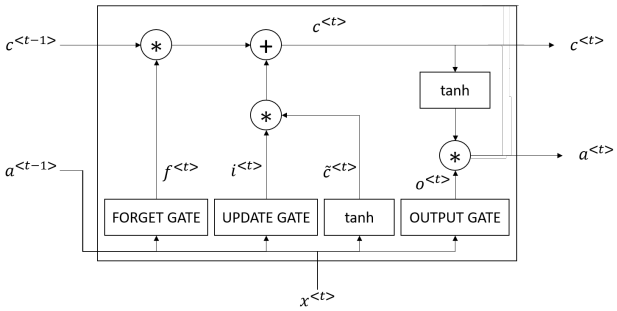

图1. 长短期记忆网络单元的内部工作原理。时间参数 t 定义为表示时间序列的输入元素。

是一个带有 Softmax 激活函数的全连接层，具有n 个类别 输出神经元；该参数会因数据集而异，见图 2。此外，其在 TensorFlow（版本 2.4.1）中的实现包含 330240 个参数，分类层的参数除外；对于 8、23 和 24 个类别，分类层参数分别为 1032、2967 和 3096。关于超参数，我们采用批量大小为 256 个样本，并使用带循环学习率的 Adam 优化器，以防止收敛到局部最优解；学习率在 $1 \cdot 10^{-7}$ 和 $1 \cdot 10^{-3}$之间振荡。最后，该网络从头开始训练，共进行 300 个训练轮次。该框架旨在

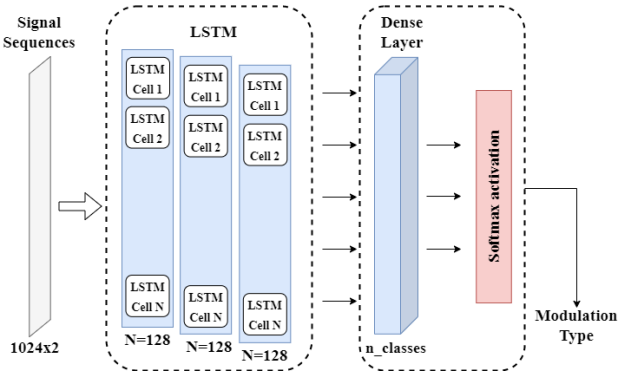

图2. 用于信号分类的框架，由三个堆叠的LSTM层和一个全连接层构成。

使用所提出的数据集进行训练、验证和测试。为了评估该神经网络的性能，采用了三个主要指标：

- 所有类别相对于信噪比的平均准确率。
- 达到90%分类准确率时的最低信噪比（灵敏度）。
- 关于信噪比的混淆矩阵。

V. 结果

本节展示所提出框架在两个雷达数据集和一个通信数据集上的性能随不同参数变化的情况。首先，通过改变长短期记忆层的数量，根据网络结构的复杂程度评估网络性能。为此，我们在包含八种调制方式的雷达数据集上进行了训练

，并考虑到这是类别数量较少的最简单情况。图3显示，使用1层与使用2层和3层长短期记忆层时的性能存在显著差距。由于3层长短期记忆网络取得了最佳结果，后续将采用这种结构评估雷达数据集和通信数据集的性能。

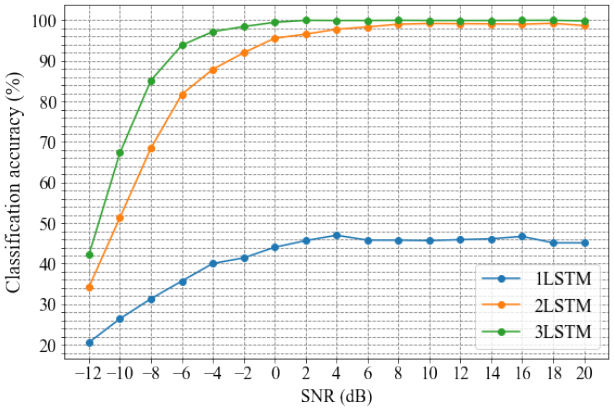

图 3. 使用 8 类雷达数据集 [7] 比较采用 1、2 和 3 个堆叠长短期记忆网络层的网络性能。

A. 雷达信号：*8* 类数据集

我们的框架的性能与 8 类数据集的作者和 SABLNet 框架 [7] 所取得的结果进行了比较。他们提出的结构复杂度更高，包含卷积神经网络、双向长短期记忆网络和注意力层。

本节展示了两项研究的结果。首先，我们考察了信号域的影响，即网络处理时域信号还是自相关域信号时是否能够取得更好的结果。与原始时序相比，我们的结果并未显示自相关域中的序列有显著提升，这表明我们的网络是从原始信号信息中学习的，与 [7] 中作者所述的结论相反；参见图 4 和图 5。尽管与 SABLNet 的结果相比，在较低信噪比下平均分类准确率并未提升，但我们的网络和 SABLNet 获得 90% 分类准确率所需的最低信噪比仍为 -10 dB。

其次，我们研究了输入数据的信噪比范围的影响：将训练样本的信噪比从 -12:2:20 dB 调整为 -20:2:20 dB，并使用 -20 至 20 dB 的完整范围进行测试，见图4。在这些情况下，我们的网络似乎具有鲁棒性且不敏感，同时在高信噪比场景下保持了分类准确率。

B. 雷达信号：*DeepRadar2022*

在本节中，我们使用了合成数据集 Deep-Radar2022，这是一个更复杂的数据集，包含 23 种信号类型（见表I）。

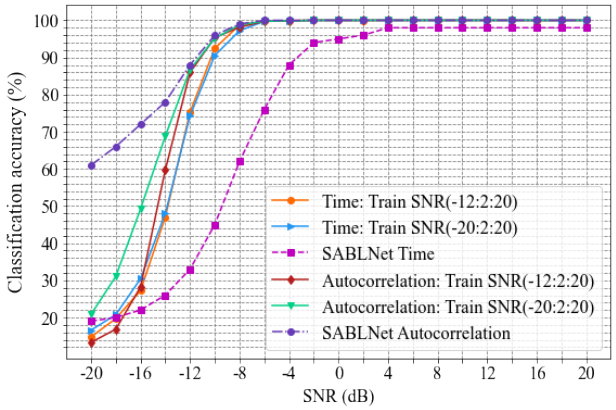

图4. 与 SABLNet 相比的平均分类准确率，研究输入数据的域和信噪比范围对比 8 类数据集的影响 [7]。

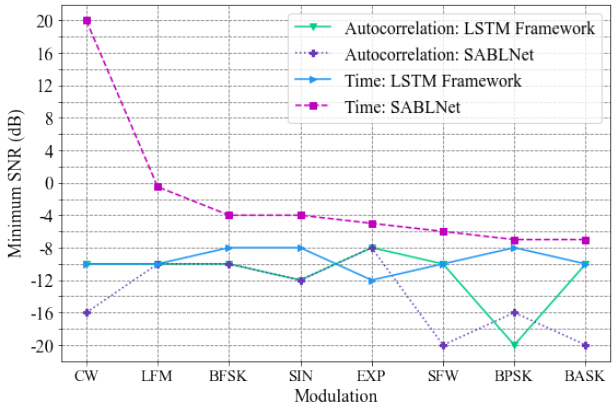

图5. 对于使用 8 类雷达数据集 [7] 的时域和自相关域序列，比较我们的框架与 SABLNet 对每种信号调制的灵敏度。

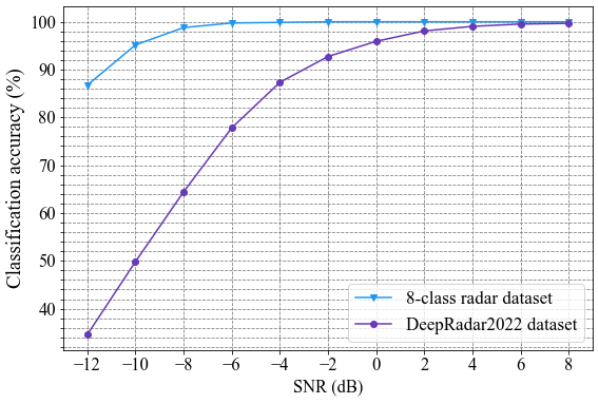

图 6. 使用 DeepRadar2022 和 8 类雷达数据集对时域序列的平均分类准确率进行比较 [7]。（曲线在 *8 dB* 后保持不变，因此已截去信噪比轴的一部分）

由于类别数量增加，灵敏度有所下降：在8类数据集中为-10 dB，而在DeepRadar2022中为-2 dB，见图6。此外，图7中的灵敏度图在高阶

连续波PSK（4PSK和8PSK）处出现了一些峰值。图8中的混淆矩阵也体现了这一点，其中4PSK和8PSK会被误分类为对方。可以通过将它们统一分类为PSK，再进一步区分阶数来改善这一局限。类似地，一些采用Frank码和P1至P4码的相位调制信号也会被错误分类为其他类别。

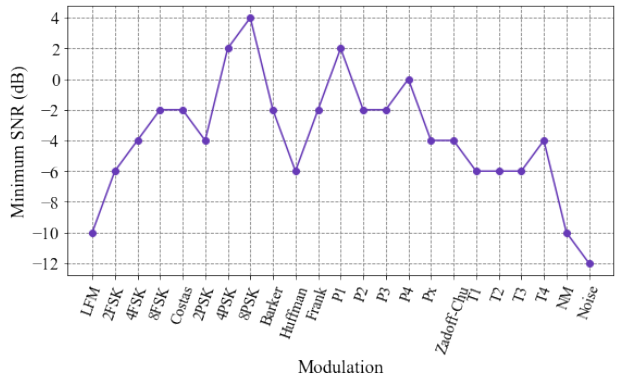

图7. 使用DeepRadar2022数据集时，各信号调制方式达到90%分类准确率时的灵敏度。

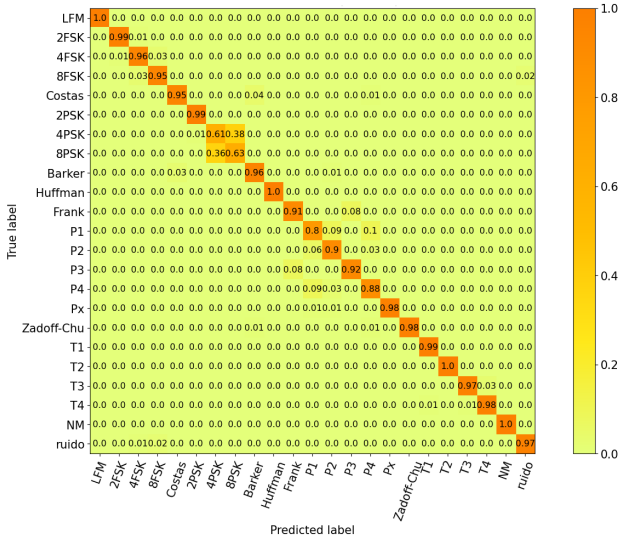

图8. DeepRadar2022数据集在信噪比为 = -2 dB时的混淆矩阵，展示了高阶相位调制的误分类情况。

C. 通信信号

我们的网络使用包含 24 种调制类型的 RadioML 2018.01A数据集进行训练和测试。在他们的工作中，研究人员提出了一种具有残差堆栈的网络 [9]。同样，我们将平均分类准确率与 GGCNN [22] 和 SE-MSFN [23],的作者所获得的结果进行了比较，见图 9。结果表明，需要达到 6 dB 的信噪比才能获得 90% 的分类准确率。由于高阶PSK和 QAM 的分类以及 AM-DSB 与 AM-SSB 的辨别较为困难，因此该数值较高

载波（WC）和抑制载波（SC）。与其他方案相比，我们的框架性能更优，但与 SE-MSFN 的性能相近。然而，就复杂度而言，我们的框架更为简单，省去了特征提取步骤，且层数更少。

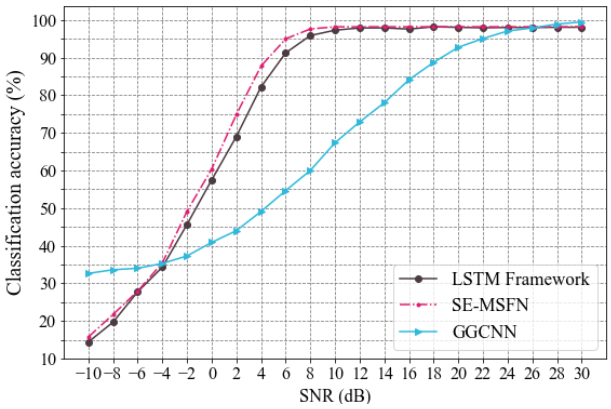

图9. 使用RadioML 2018.01A数据集时，我们的框架与GGCNN [22]和SE-MSFN [23] 的平均分类准确率对比。

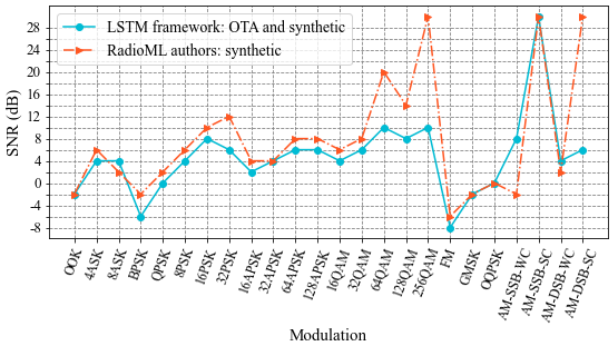

图10. 我们的框架与RadioML 2018.01A数据集作者的结果 [9]在达到90%分类准确率时的灵敏度对比。

此外，我们将各信号的灵敏度与RadioML 2018.01A的作者所报告的结果进行了比较，因为他们提供了各调制方式的分类准确率相关结果。然而，由于我们没有像原论文 [9]，那样按信号类型（合成信号或OTA采集）划分的数据集，因此无法对结果进行公平比较。尽管如此，通过分析作者仅对合成信号进行分类时的结果可以发现，部分信号（64QAM、AM-DSB-SC、AM-SSB-SC和256QAM）在评估的最高信噪比（20 dB）下仍未达到90%的准确率。相比之下，我们的实验表明，除AM-SSB-SC外，所有信号在信噪比低于10 dB时均可达到90%的分类准确率，见图10。因此，对于大多数信号而言，我们的框架似乎具有更强的灵敏度。

VI. 结论

我们开发了一种基于长短期记忆网络的架构，用于对通信信号和雷达信号进行分类。我们的

实验表明，该框架在这两类信号上均达到了当前最先进的性能。

与现有的基于深度学习的自动调制分类器（AMC）相比，这些基于长短期记忆网络的分类器具有更高的灵敏度和鲁棒性，结构也更简单，因此可训练参数更少。

参考文献

[1] Zhechen Zhu 和 Asoke K. Nandi。2015。《自动调制分类：原理、算法与应用》（第1版）。Wiley 出版社。2015。[2] O. A. Dobre、A. Abdi、Y. Bar-Ness 和 W. Su，“自动调制分类技术综述：经典方法与新趋势”，发表于 IET。1。137 - 156。[3] T. Wan、K. Jiang、Y. Tang、Y. Xiong 和 B. Tang，“使用可见性图的自动低截获概率雷达信号感知方法”，发表于 IEEE Access，第8卷，第159650-159660页，2020。[4] W. Gongming、C. Shiwen、H. Xueruobai 和 Y. Junjian，“基于时频图像联合特征的雷达发射机分选与识别”，2019年IEEE第4届信号与图像处理国际会议（ICSIP），中国无锡，2019，第165-170页。[5] J. Lunden 和 V. Koivunen，“自动雷达波形识别”，发表于 IEEE Jo urnal of Selected Topics in Signal Processing，第1卷，第1期，第124-136页，2007年6月。[6] S. Rajendran、W. Meert、D. Giustiniano、V. Lenders 和 S. Pollin，“利用分布式低成本频谱传感器进行无线信号分类的深度学习模型”，发表于 IEEE Transactions on Cognitive Communications and Networking，第4卷，第3期，第433-445页，2018年9月。[7] S. Wei、Q. Qu 等，“用于雷达信号调制识别的自注意力双向长短期记忆网络”，发表于 IEEE Transactions on Microwave Theory and Techniques，69，11，第5160—5172页，2021。[8] T. Erpek、T. O’shea、Y. Sagduyu、Y. Shi 和 T. Charles Clancy，“无线通信中的深度学习”，发表于《深度学习架构的开发与分析：计算智能研究》，第223–266页，2019。[9] T. J. O’Shea、T. Roy 和 T. C. Clancy，“基于空中接口深度学习的无线电信号分类”，发表于 IEEE Journal of Selected Topics in Signal Processing，第12卷，第1期，第168-179页，2018年2月。[10] D. Li、R. Yang、X. Li 和 S. Zhu，“基于深度联合学习的雷达信号调制识别”，发表于 IEEE Access，第8卷，第48515-48528页，2020。[11] Z. Qu、W. Wang、C. Hou 和 C. Hou，“基于卷积去噪自动编码器和深度卷积神经网络的雷达信号脉内调制识别”，发表于 IEEE Access，第7卷，第112339-112347页，2019。[12] T. O’shea、J. Corgan 和 T. Charles Clancy，“卷积无线电调制识别网络”，发表于《神经网络工程应用：计算机与信息科学通信》，第213–226页，2016。O’Shea、Tim & Corgan、Johnathan & Clancy、T.（2016）。卷积无线电调制识别网络。[13] W. Yongshi、G. Jie、L. Hao、L. Li、W. Zhigang 和 W. Houjun，“复杂通信信道中的基于卷积神经网络的调制分类”，2017年第13届IEEE电子测量与仪器国际会议（ICEMI），中国扬州，2017，第512-516页。[14] S. Peng 等，“基于信号星座图和深度学习的调制分类”，发表于 IEEE Transactions on Neural Networks and Learning Systems，第30卷，第3期，第718-727页，2019年3月。[15] K. Yashashwi、A. Sethi 和 P. Chaporkar，“用于调制识别的可学习失真校正模块”，ssh，发表于 IEEE Wireless Communications Letters，第8卷，第1期，第77-80页，2019年2月。[16] R. Li、L. Li、S. Yang 和 S. Li，“基于深度卷积神经网络的鲁棒自动甚高频调制识别”，发表于 IEEE Communications Letters，第22卷，第5期，第946-949页，2018年5月。[17] Z. Liu、L. Li、H. Xu 和 H. Li，“基于深度卷积神经网络的混合信号识别与分类方法”，2018年电子技术国际会议（ICET），中国成都，2018，第325-330页。[18] D. Wang、M. Zhang、J. Li 等，“使用基于卷积神经网络的深度学习的智能星座图分析仪”，发表于 Optics Express，25，15，第17150—17166页，2017。

[19] S. Peng, H. Jiang, H. Wang, H. Alwageed 和 Y. -D. Yao，“使用基于卷积神经网络的深度学习模型进行调制分类”，2017 年第 26 届无线与光通信会议（WOCC），美国新泽西州纽瓦克，2017 年，第 1-5 页。[20] H.Wu、Q.Wang、L. Zhou 等，“基于卷积神经网络的甚高频无线电信号调制分类”，发表于 Matec Web of Conferences，246，2018 年。[21] Z. Liu、L. Li、H. Xu 和 H. Li，“一种基于深度卷积神经网络的混合信号识别与分类方法”，发表于 2018 年国际电子技术会议（ICET）论文集，第 325–330 页，2018 年。[22] P. Ghasemzadeh、M. Hempel、H. Wang 和 H. Sharif，“GGCNN：一种旨在最大限度提高效率的门控图卷积神经网络架构，用于自动调制识别”，*IEEE* 无线通信汇刊。第 1-1 页（2023 年）[23] X. Wu、S. Wei 和 Y. Zhou，“用于自动调制分类的注意力深度多尺度表征学习”，*2022* 年国际神经网络联合会议（*IJCNN*），意大利帕多瓦，2022 年，第 1-8 页。[24] C. Wang、J. Wang 和 X. Zhang，“基于时频分析和卷积神经网络的雷达波形自动识别”，发表于 2017 年 IEEE 国际声学、语音与信号处理会议（ICASSP），2017 年。[25] J. Wan、X. Yu 和 Q. Guo，“基于卷积神经网络和 TPOT 的低截获概率雷达波形识别”，发表于 Symmetry，11，5，2019 年。[26] Z. Qu、C. Hou、C. Hou 和 W. Wang，“基于卷积神经网络和深度 Q 学习网络的雷达信号脉内调制识别”，发表于 IEEE Access，第 8 卷，49136，2020 年 49125页。-。[27] Z. Zhou、G. Huang 和 H. Chen，“基于深度卷积去噪自编码器的雷达波形自动识别”，发表于 Circuits Systems and Signal Processing，37，9，第 4034–4048 页，2018 年。[28] Z. Liu、X. Mao、Z. Deng 等，“基于卷积去噪自编码器的雷达信号波形识别”，发表于国际通信会议论文集，第 752–761 页，2018 年。[29] Q. Wang、P. Du、J. Yang 等，“基于迁移深度学习的认知无源雷达波形识别”，发表于 Signal Processing，第 259–267 页，2019 年。[30] S. Wei、Q. Qu、H. Su 等，“基于 CLDN 网络的脉内调制雷达信号识别”，发表于 IET Radar, Sonar and Navigation，14，6，第 803–810 页，2020 年。[31] X. Li、Z. Liu 和 Z. Huang，“基于注意力机制的循环神经网络雷达 PRI 调制识别”，发表于 IEEE Access，8，第 57426–57436 页，2020 年。[32] Z. Liu 和 P. Yu，“使用循环神经网络对脉冲流进行分类、去噪和解交织”，发表于 IEEE 航空航天与电子系统汇刊，4，55，第 1624–1639 页，2019 年。[33] X. Li、Z. Liu、Z. Huang 和 W. Liu，“基于注意力机制的多循环神经网络雷达发射机分类”，发表于 IEEE Communications Letters，9，24，第 2000–2004 页，2020 年。[34] S. Hochreiter、J. Schmidhuber，“长短期记忆”，发表于 Neural Computation，第 9 卷，第 8 期，第 1735–1780 页，1997 年。[35] L. Smith，“用于训练神经网络的循环学习率”，发表于 2007 年 IEEE 冬季计算机视觉应用会议（WAVC），9，24，第 2000–2004 页，2017 年。