白皮书

使用通信和雷达的综合数据实现深度学习

MathWorks®

本白皮书演示如何使用 MATLAB® 实现雷达和通信应用中的调制识别和目标分类。您将了解如何：

1. 合成并标注雷达和通信波形
2. 生成移动物体的雷达回波
3. 使用综合数据训练深度网络
4. 使用深度学习和机器学习技术执行波形调制识别和目标分类
5. 使用从软件无线电和雷达系统中收集的数据测试您的系统

本白皮书将通过三个应用示例来演示可能的工作流程。前两个示例使用深度学习来识别波形调制类型。第三个示例使用雷达回波，根据雷达散射截面 (RCS) 和运动特征来识别物体。

这些示例展示如何使用 Phased Array System Toolbox™ 和 Communications Toolbox™ 合成通信和雷达基带波形及反射雷达波的对象，以及如何使用 Deep Learning Toolbox™ 和 Statistics and Machine Learning Toolbox™ 配置、训练和实现学习网络。

背景

调制识别和目标分类是智能接收器的重要功能。这些功能在认知雷达、软件无线电 (SDR) 和高效频谱管理方面有诸多应用。要识别通信和雷达这两种波形，有必要按调制类型进行分类。为此，您可以提取能输入到分类器的有意义的特征。这个做法虽然有效，但可能需要投入一定的精力且具备相应的领域知识，才能做到准确识别。目标分类也存在类似的挑战。

本白皮书介绍了一种从接收到的信号中自动提取时频特征的框架，然后您可以使用这些特征，通过深度学习网络执行分类。您可以使用一系列技术将信号馈送到深度学习网络，如下面的示例所示。

为了支持这些工作流程，您可以生成并标注带有信道特性的合成波形。这些生成的波形转而为一系列深度学习网络提供训练数据。对于目标分类，您还可以建立对象模型，对这些反射雷达波的目标进行仿真。在这两种情况下，您都可以使用来自 SDR 和雷达的 over-the-air 信号验证所生成的系统。

图 1 显示调制识别和分类的工作流程。您可以遵循类似的工作流程，使用雷达回波进行对象分类。

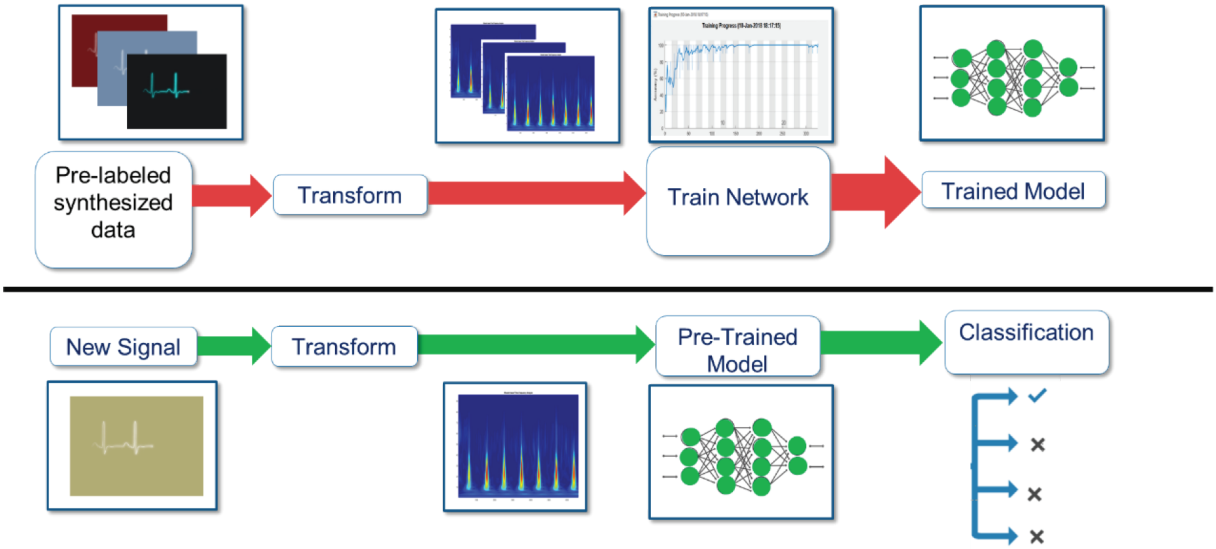

图 1. 使用 MATLAB 开展深度学习的调制识别工作流程。

波形调制识别

调制识别充满挑战，因为任何给定频带中都存在各种波形。除了拥挤的频谱以外，就传播条件和非合作的干扰源来说，环境也可能十分严酷。在您进行调制识别时，可能出现的问题包括：

- 这些信号如何向接收器呈现自己？
- 如何处理以前未接收过的非预期信号？
- 信号如何相互作用或相互干扰？

您可以运用机器学习和深度学习技术，进行调制识别。首先要考虑在手动提取特征来训练机器学习算法所需的时间与训练深度学习网络所需的大数据集之间进行权衡。再考虑每个方法的计算要求。图 2 显示这些权衡的关系。

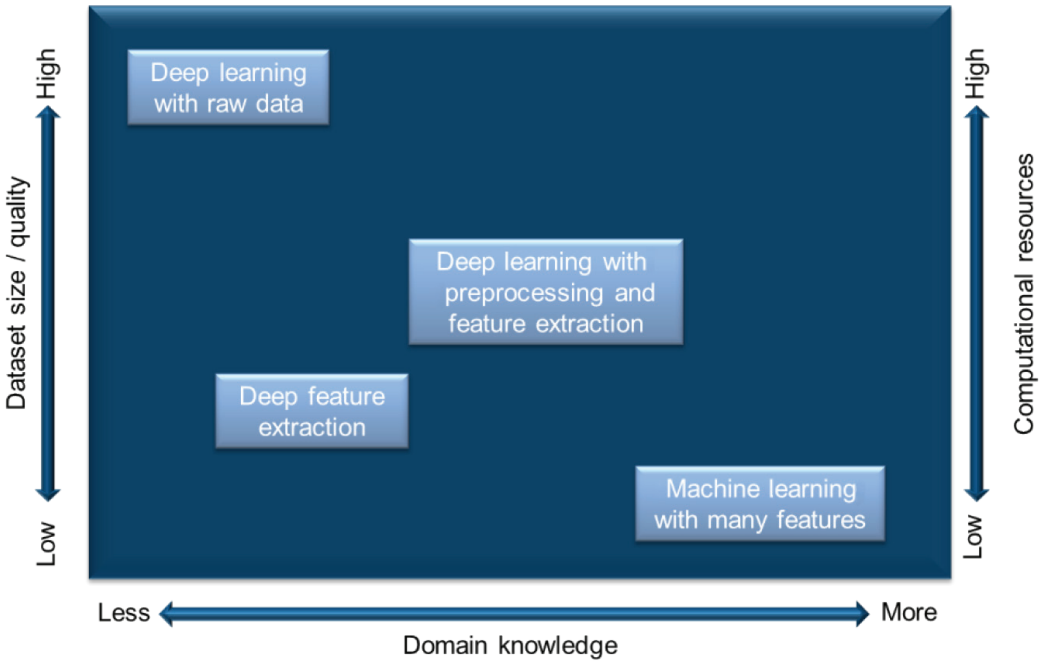

图 2. 所需训练数据集大小、领域知识和计算资源之间的权衡。

手动提取特征可能很花时间，而且该过程需要详实的信号知识。另一方面，深度学习网络需要大量的数据进行训练，以确保获得最佳结果。使用深度学习网络的一个好处是预处理工作和手动提取特征的工作少。

随着在自动驾驶和计算机视觉领域对感知功能需求的不断增加，组织机构正在大力投资基于图像和视觉的学习技术，而雷达和通信等其他基于信号的应用也可以利用这种学习技术。无论数据集包含原始数据还是预处理数据都是这样。

在下面的示例中，深度学习网络在分类方面担负起了“重任”，您可以重点关注满足训练和验证的数据集需求的最佳方式。虽然可以从现场系统中生成数据，但收集和标注此类数据却是一个挑战。跟踪记录波形以及同步发送和接收系统会导致产生可能难以管理的大型数据集。协调不在同一地点的数据源也是一个挑战，包括经历各种条件的测试。另外，标注此类数据也需要投入大量精力，无论是在收集数据时还是在事后，因为真值可能不是一直可用或可靠。

另一选项是使用合成数据，因为生成、管理和标注合成数据要容易得多。问题是合成数据的保真度是否足够。在后面的用例中，您会看到，生成高保真合成数据是可能的。

合成雷达和通信波形

如前所述，已占用的频谱十分拥挤，通信系统、无线电和导航系统等发射源全都在竞争频谱。要创建测试方案，请考虑以下各种各样的波形类型：

- 方波
- 线性频率调制 (LFM)
- 巴克码
- 高斯频移键控 (GFSK)
- 连续相位频移键控 (CPFSK)
- 广播调频 (B-FM)
- 双边带调幅 (DSB-AM)
- 单边带调幅 (SSB-AM)

利用这些定义的波形，您能够以编程方式为每个调制类型生成大量的 I/Q 信号。每种波形都有各自独一无二的参数，所生成的信号会与各种噪声相混合，以提高模型的保真度。对于每种波形，脉冲宽度和重复频率是随机生成的。对于 LFM 波形，扫描带宽和线性调频方向是随机生成的。对于巴克波形，码片时宽和数量是随机生成的。所有信号都与高斯白噪声混合。另外，对每个信号都应用了具有随机载波频率的频率偏移。最后，每个信号都通过一个信道模型进行传递。在此示例中，实现了多路径莱斯衰落信道，但也有其他模型可供使用。

准备馈送给训练网络的数据在生成时即被标注。

使用时频技术提取特征

要提高学习算法的分类性能，一个常见方法是输入提取的特征，而不是原始信号数据。这种特征是输入数据的另一种表示形式，将使分类算法更容易分辨各个类。

在实际应用中，很多信号都是非平稳的。这就是说，它们的频域表示形式随时间而改变。提取特征的一个有用技术是时频变换，这会产生一个图像，供导入分类算法中。时频变换可帮助识别有用信号中是否存在特定的频率分量或间歇干扰。

许多自动化技术都适用于时频变换，包括频谱图和连续小波变换 (CWT)，而 Wigner-Ville 分布 (WVD) 是个很好的入门算法，因为它提供不错的频谱分辨率，而没有其他技术中出现的泄漏效应。

Wigner-Ville 分布呈现原始数据的时频视图，对于时变信号非常有用。它在时间和频率域中的高分辨率特性和局部性提供了良好的特征，有助于区分相似的调制类型。但是，如果存在多个频率分量的交叉项，WVD 性能将降级。这是您可以计算每种调制类型的平滑伪 WVD。图 3 显示一组数据的降采样图像。

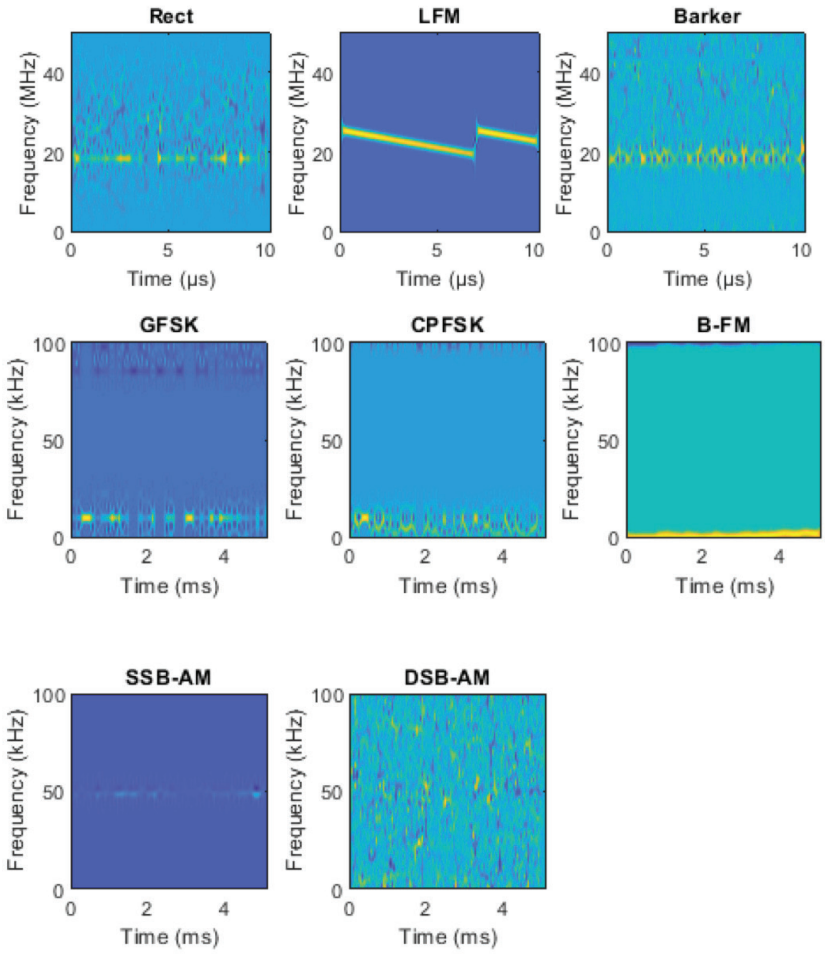

图 3. 雷达和通信波形的时频表示形式。

您可以使用这些图像训练深度卷积神经网络 (CNN)。该网络使用 80% 的数据集进行训练，10% 用于测试，10% 用于验证。

设置和训练深度学习网络

在训练深度学习网络之前，必须定义网络架构。此示例的结果是使用迁移学习通过 AlexNet 获得的，该网络是为图像分类而创建的一个深度 CNN。迁移学习用于重新训练现有神经网络来对新目标分类。AlexNet 在其默认配置中执行 1000 个类别的分类。为了针对此数据集调整 AlexNet，我们修改最后三个分类层，使其只对我们的八个调制类型进行分类。也可以利用其他更小规模的网络（如 SqueezeNet）来完成此工作流程。

创建 CNN 之后，便可以开始训练。由于数据集很大，最好使用 GPU 或多核处理器进行加速。图 4 显示使用 GPU 加速训练的随时间变化的训练进度。训练进度通过准确度与迭代次数之间的函数关系来表示。验证准确度超过 97%。

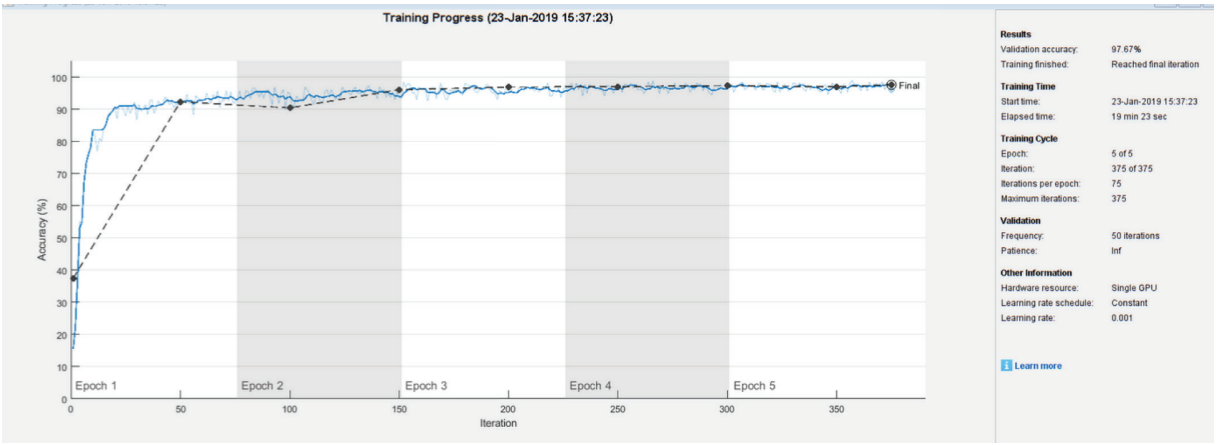

图 4. 使用 GPU 加速处理训练进度。

评估性能

上面说过，保留 10% 的生成数据用于测试。对于输入到网络的八个调制类型，超过 99% 的 B-FM、CPFSK、GFSK、巴克码、方波和 LFM 调制类型被正确分类。平均算起来，有超过 85% 的 AM 信号得到正确识别。如图 5 中的混淆矩阵所示，有较大比例的 DSB-AM 信号被错误分类为 SSB-AM，SSB-AM 被分类为 DSB-AM 的比例也很高。

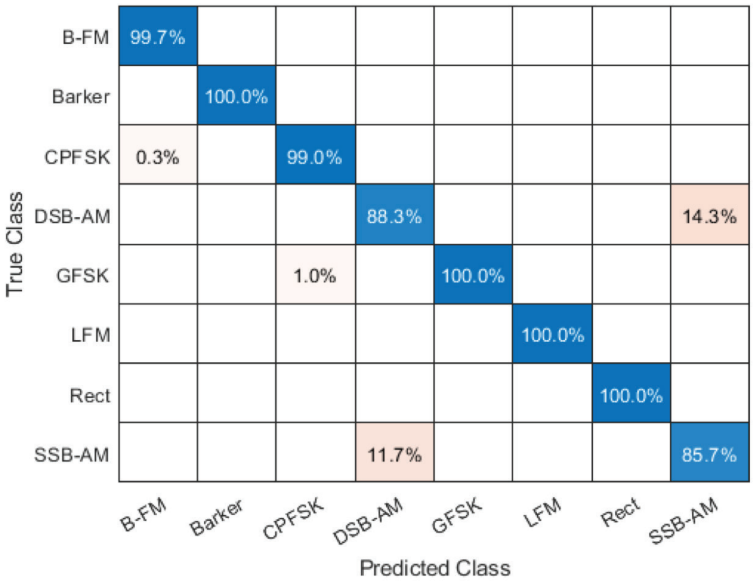

图 5. 分类结果的混淆矩阵。

此工作流程的框架支持进行误分类的调查，以深入了解网络的学习过程。由于 DSB-AM 与 SSB-AM 信号的签名非常相似，这在某种程度上正好解释了为何网络难以对这两种类型进行正确分类。进一步执行连续小波变换 (CWT) 等信号处理，可以让网络更加清晰地区分这两种调制类型，从而提高分类质量。尤其是 CWT 提供了更好的多分辨率分析，为网络提供更好的与信号频率突变相关的信息。

在接下来的示例中，您会看到向网络中输入数据的一种替代技术。另外，您还会看到如何将无线电数据用于测试阶段。

使用 I/Q 数据的替代方法

开始时，生成新的数据集，其中包括以下 11 个调制类型 (8 个数字类型和 3 个模拟类型)：

- 二进制移相键控 (BPSK)
- 四进制移相键控 (QPSK)
- 8 进制移相键控 (8-PSK)
- 16 进制正交幅度调制 (16-QAM)
- 64 进制正交幅度调制 (64-QAM)
- 4 进制脉冲幅度调制 (PAM4)
- 高斯频移键控 (GFSK)
- 连续相位频移键控 (CPFSK)
- 广播调频 (B-FM)
- 双边带调幅 (DSB-AM)
- 单边带调幅 (SSB-AM)

其中，每个调制类型都生成了 10,000 帧。同样，该网络使用 80% 的数据进行训练，10% 用于验证，10% 用于测试，如图 6 中所示。

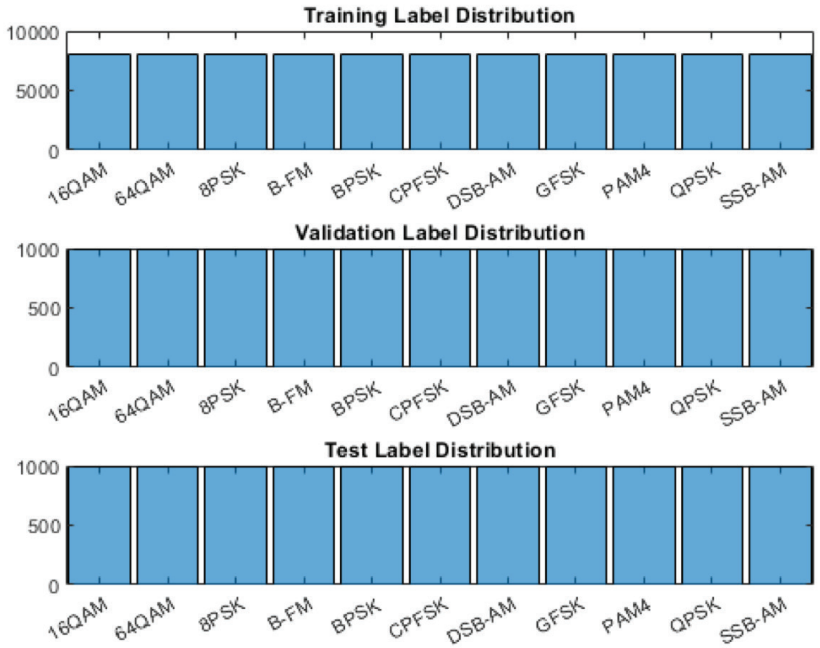

图 6. 已标注的数据集按波形类型分布。

对于数字调制类型，使用 8 个样本来表示一个符号。网络根据单个帧而不是多个连续帧做出每个决定。与我们的第一个示例相似，每个信号通过具有加性高斯白噪声 (AWGN)、Rician 多路径衰落和随机时钟偏移的信道进行传递。每个调制类型所产生的信道减弱的帧都随其相应的标签一起存储。为了让该方案更加符合实际，每个帧开头的随机数量的样本被移除，以消除瞬变并确保这些帧有相对于符号边界的随机起点。图 7 显示每个波形类型的时间和时频表示形式。

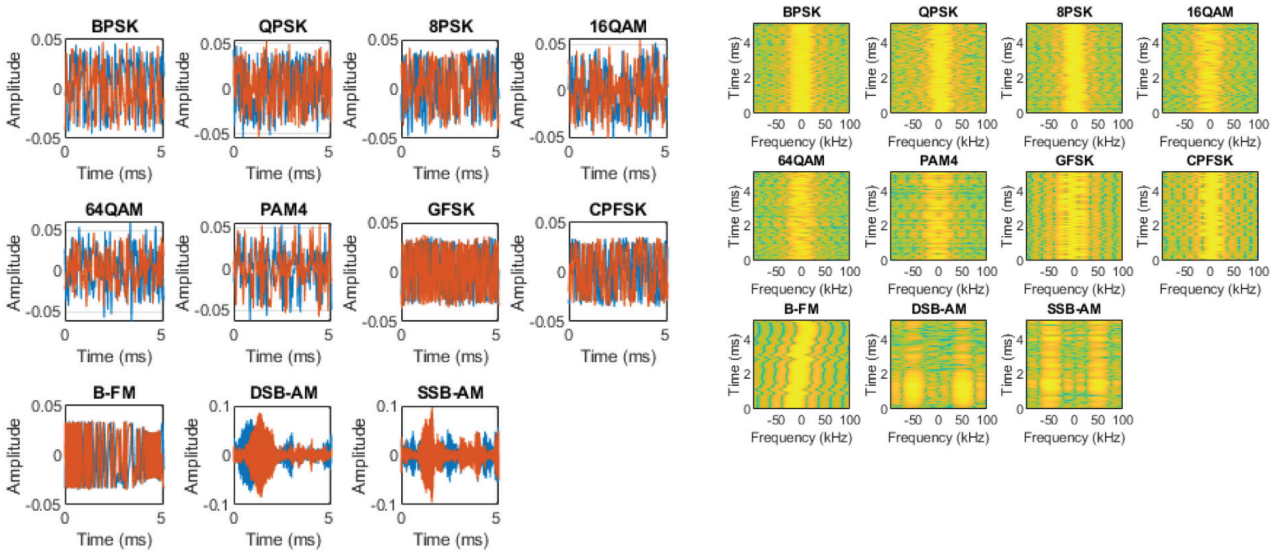

图 7. 所生成波形的时间表示形式（左）和相应的时频表示形式（右）的示例。

训练 CNN 并评估结果

此示例使用由六个卷积层和一个全连接层组成的 CNN。每个卷积层（最后一个除外）后接一个批归一化层、修正线性单元 (ReLU) 激活层和最大池化层。在最后一个卷积层中，最大池化层替换为平均池化层。要训练这个网络，同样要使用 GPU 来加速处理。

在上一示例中，每个数据镜像都变换为一个图像。此示例实现了一个替代方法，即直接使用 I/Q 基带样本，而没有进一步预处理。

为此，您可以按行使用 I/Q 基带样本，作为二维阵列的一部分。在这里，卷积层独立处理同相分量和正交分量。只有在全连接层中，才组合同相分量和正交分量的信息。此方法可达到 90% 的准确度。

此方法的一个变体是将 I/Q 样本用作三维阵列；其中，同相分量和正交分量是第三维（页）的一部分。此方法在卷积层中均匀地混合 I 和 Q 中的信息，可以更好地利用相位信息。

如图 8 中所示的混淆矩阵，使用页（而不是行）表示 I/Q 分量可以极大地提高网络准确区分 16-QAM 和 64-QAM 帧以及 QPSK 和 8-PSK 帧的能力。该变体可达到 95% 的总体准确度，比前一个方法提高了大约 5%。

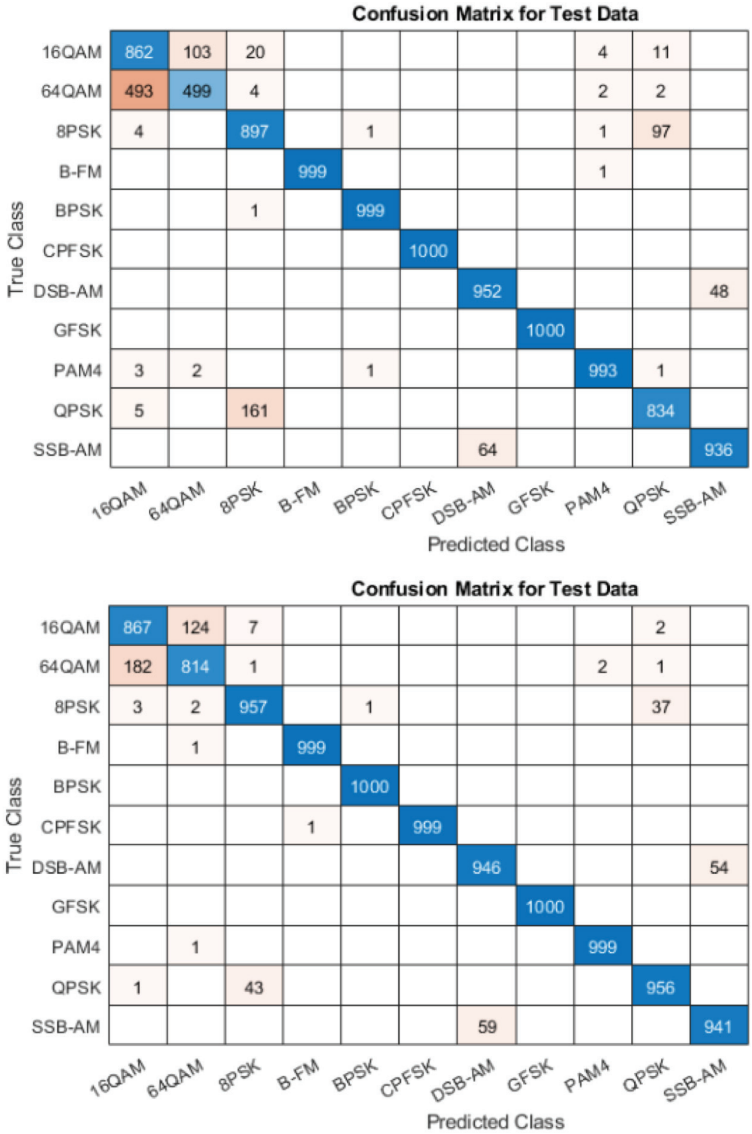

图 8. 包含以行（顶部）表示和以页（底部）表示的 I/Q 分量的结果。

使用 SDR 和雷达系统进行测试

可以只使用合成数据测试您的系统。也可以使用 over-the-air 信号测试您的系统。为了演示这一点，使用桌面上配置的两个静止不动的 ADALM-PLUTO 软件无线电生成通信波形。该网络实现了 99% 的总体准确度，如图 9 中所示。鉴于桌面配置更简单这一本质，这比用合成数据获得的结果要好。对于在更真实的场景中收集的雷达和无线电数据，此工作流程也可扩展支持。

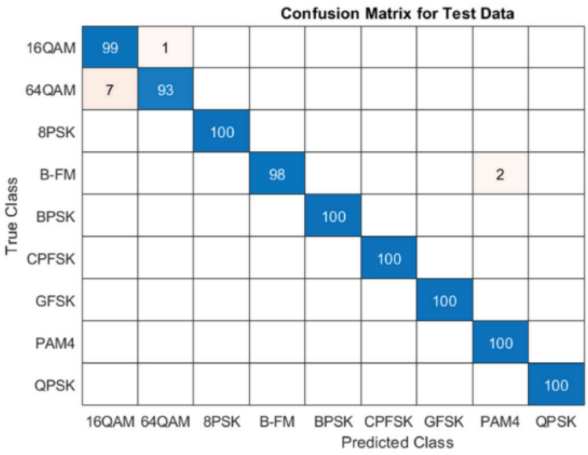

图 9. 使用 ADALM-PLUTO 无线电的 SDR 配置（左）和相应的混淆矩阵（右）。

图 10 显示了 Analog Devices 的 DemoRad 平台，该平台也可直接与 MATLAB 交互。您可以通过此软件定义雷达收集数据和处理基带数据。您可以使用这种类型的雷达系统收集数据，并通过扩展上述示例来识别数据。

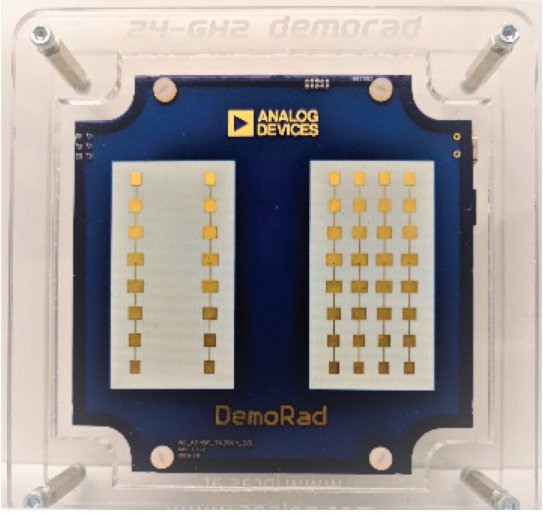

图 10. Analog Devices DemoRad 雷达评估板。

对象分类

如以上所述，可以使用深度学习技术识别雷达波形，而这些波形也可用作更大的雷达系统模型的一部分。在这种类型的仿真中，波形从阵列中发出，通过传播信道进行传递，被雷达视野内的物体上反射回来，然后雷达接收回波。在本节的下一个示例中，您将看到如何运用机器学习技术对雷达视野内的对象进行分类。

可以使用随角频率而变化的 RCS 进行对象建模。在这个简单的示例中，圆柱和圆锥体表示雷达视野内的物体。图 11 显示了一个圆柱在不同视界角上的 RCS。另外还显示每个对象的运动模型轮廓的示例，以及单个数据集相应的雷达回波。在这种情况下，假设形状经历一种运动，造成视轴周围发生小振动；这样，视界角的变化将体现在样本之间。

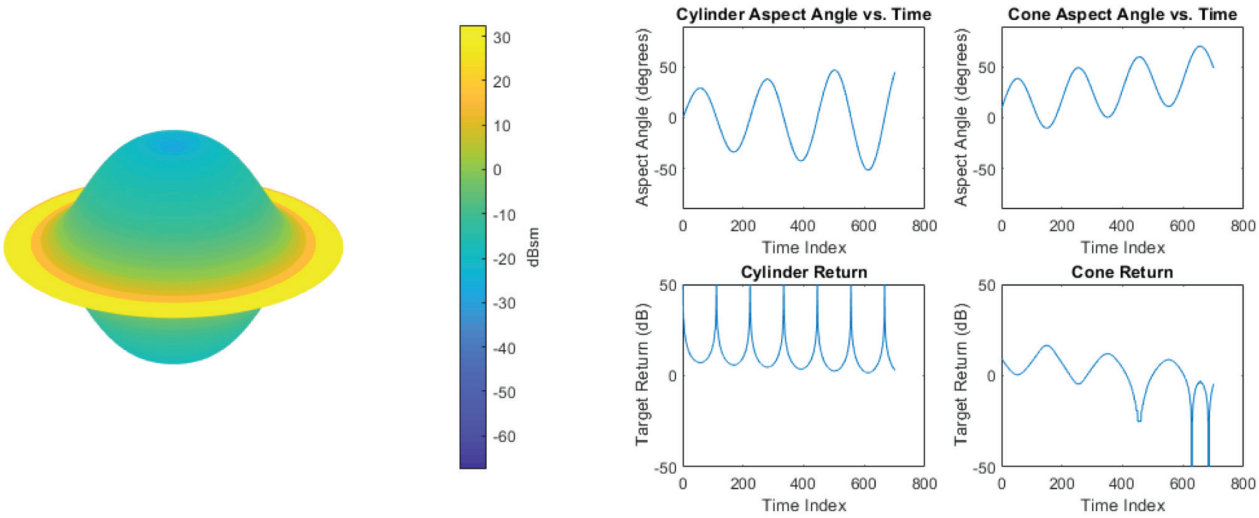

图 11. 圆柱的 RCS（左）和运动模型的示例以及圆柱和圆锥体的雷达回波。

同样，您可以随许多其他形状一起生成圆锥体的雷达回波。使用此建模和仿真作为基础，您可以生成很多数据集，从而可以用不同的形状特征和运动变体训练网络。在转移到您的现场硬件之前，而且面临着前面章节讨论的同样的数据收集和标注挑战，这可能是更高效的数据生成方式。

为了提高学习算法的匹配性能，您可以使用特征提取，让分类算法更加容易区分来自不同目标的回波。此外，特征通常比原始信号规模小，所以学习需要的计算资源较少。

在此示例中，信号的时频签名使用该信号的小波包表示形式。图 12 显示圆锥和圆柱体的小波包签名。这些签名提供了某种洞察力，而学习算法将能够区分这两者。具体来说就是，在这两个签名之间，随时间变化的频谱具有很好的区分度。

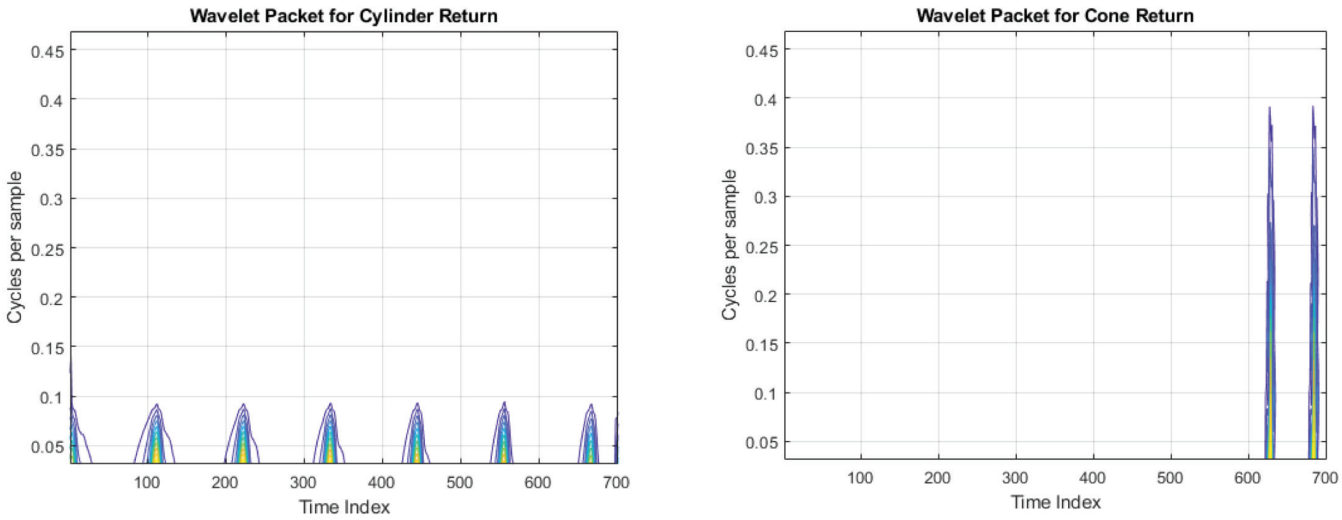

图 12. 圆柱和圆锥体的小波变换表示形式。

圆柱和圆锥体回波之间的频率分离特性提示我们使用频域测量来对信号分类。

提取的特征集由每个目标回波8个预测单元组成。与 701 个点的原始时域信号相比，这是显著的数据缩减。您可以调节小波变换的级别数，从而提高分类算法的性能。

您可以使用图 13 所示的 Classification Learner 应用程序来训练分类器。在加载训练数据后，该应用程序可以帮助对数据集应用不同的学习算法，提供相应的分类精度。

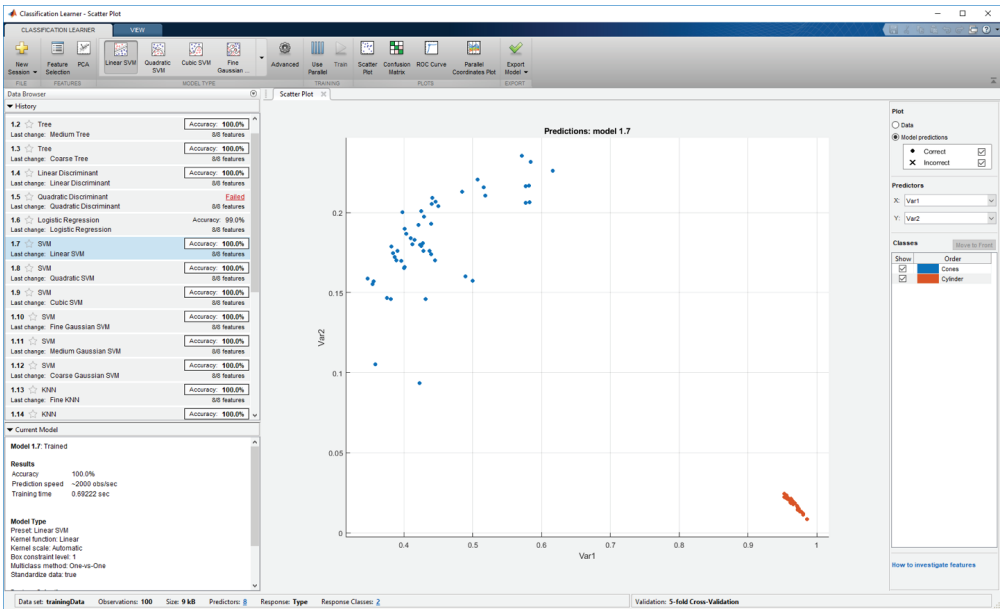

图 13. Classification Learner 应用程序。

在模型准备就绪后，网络便可以处理接收到的目标回波并执行分类。这些数据将通过训练好的分类器，看看它能否对这两个形状正确分类。测试数据包含 25 个圆柱体回波和 25 个圆锥体回波。这些圆柱和圆锥体由每个形状的 5 个尺寸以及每个尺寸的 5 个运动剖面组成。生成过程与训练数据相同，但由于尺寸值和入射角值的随机性，具体的值稍有差异。每个形状的样本总数为 701x25，可以达到的准确度为 82%。

通过提高训练数据的质量和数量，可以提高分类器的性能。另外，还可以改进特征提取流程，在分类算法内进一步区分每个目标的特点。注意，不同的特征可能有不同的最佳分类算法。

对于更加复杂的数据集，使用卷积神经网络和长短期记忆 (LSTM) 循环神经网络的深度学习工作流程也会提高性能。下面的链接更加详细地演示了这些工作流程。

小结

MATLAB 使您能够从信号中自动提取时频特征。您可以使用这些特征，通过深度学习网络执行调制和目标分类。您可以生成并标注带有信道特性的综合波形和雷达回波，可以为了训练目的进行扩充或替换实时数据。然后，您可以使用来自软件无线电 (SDR) 和雷达的 over-the-air 信号验证这些类型的系统。

了解更多

有关以上示例的更加详细的描述和 MATLAB 脚本，请参阅：

- *使用深度学习进行雷达波形分类* - 示例
- *使用深度学习进行调制分类* - 示例
- *使用机器学习进行雷达目标分类* - 示例

© 2019 The MathWorks, Inc. MATLAB and Simulink are registered trademarks of The MathWorks, Inc. See mathworks.com/trademarks for a list of additional trademarks.
Other product or brand names may be trademarks or registered trademarks of their respective holders.