

ホワイトペーパー

通信およびレーダー向け ディープラーニング活用法

このホワイトペーパーでは、MATLAB® を使用して変調識別およびターゲット分類を、レーダーと通信アプリケーションに使用する方法について説明します。以下を行う方法についてご紹介します。

1. レーダーと通信波形を合成してラベル付け
2. 移動する物体のためのレーダー信号の生成
3. 合成データでディープネットワークを学習
4. ディープラーニングと機械学習を使用した波形変調 ID とターゲット分類
5. ソフトウェア無線とレーダーシステムから収集されたデータでシステムをテスト

これらのアプリケーション例では可能なワークフローを説明します。最初の 2 つの例では、ディープラーニングを使用して波形変調タイプを識別します。3 つ目の例では、レーダー信号を使用し、RCS (レーダー断面積) と運動特性に基づいて物体を識別します。

これらの例では、Phased Array System Toolbox™ と Communications Toolbox™ を使用して、通信およびレーダーベースバンド波形と物体からのレーダー反射を合成して、Deep Learning Toolbox™ と Statistics and Machine Learning Toolbox™ を使用して学習ネットワークを構成、学習、実装する方法について示します。

背景

変調識別とターゲット分類はインテリジェントな受信機にとって重要な機能になります。これらの機能は、コグニティブレーダー、ソフトウェア無線 (SDR)、および効率的なスペクトル管理など、たくさんの適用例があります。通信とレーダー波形の双方を識別するには、変調タイプごとに分類が必要になります。これにより、分類器に入力できる意味のある特徴を抽出できます。この手順は効率的ではあるものの、正確な分類を行うための労力と分野の専門知識が必要になる場合があります。同様の難しさがターゲット分類にもあります。

このホワイトペーパーでは、受信した信号から自動的に時間周波数の特徴を抽出し、それを使用してディープラーニング ネットワークで分類を実行する方法について紹介します。以下の例で示されているように、ディープラーニング ネットワークで信号を処理する幅広い手法を使用できます。

これらのワークフローを補うため、合成かつチャンネル障害の波形を生成してラベル付けします。これらの生成された波形が、次にさまざまなディープラーニング ネットワークに学習データを提供します。ターゲット分類では、物体をモデル化して、ターゲットからのレーダー反射をシミュレーションできます。双方のケースで、SDR およびレーダーからの無線信号で最終的なシステムを検証できます。

図 1 で変調識別と分類のワークフローが示されています。これと同様のワークフローで、レーダー信号を使用した物体分類が可能です。

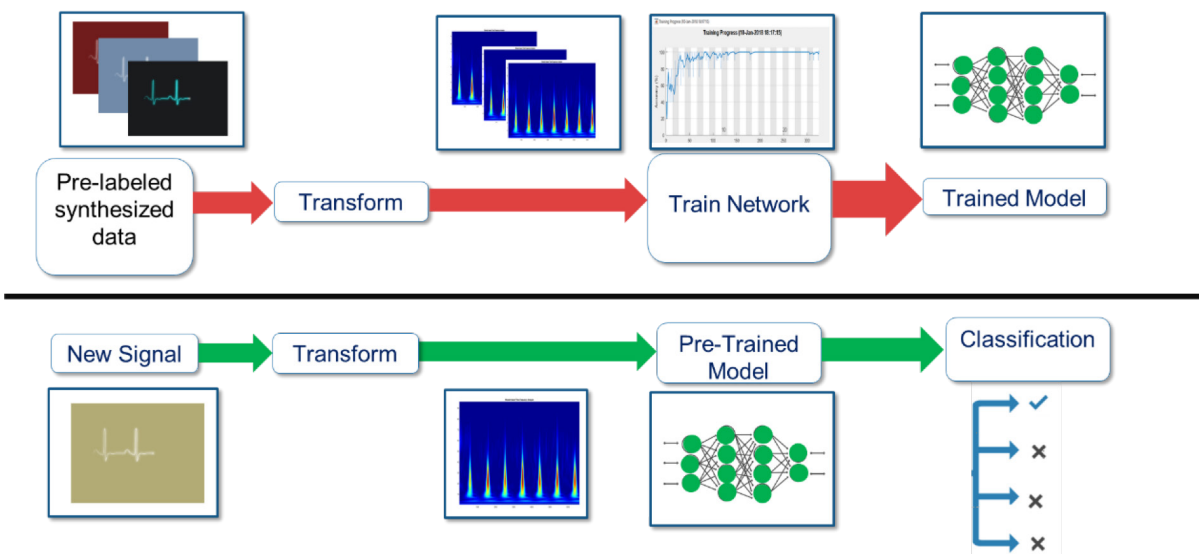


図 1. MATLAB を使用したディープラーニングでの変調識別のワークフロー

波形変調の識別

変調識別は、当該の周波数帯域にさまざまな波形の存在により困難なものとなります。たくさんのスペクトルに加えて、伝搬条件および非協力干渉源の観点から環境は厳しいものとなります。変調識別を行っているとき、次のような疑問が浮かぶかもしれません。

- これらの信号はどのように受信機に自分自身を伝えているのか？
- これまで受信されていない予期しない信号をどのように扱うべきなのか？
- それぞれの信号はどのように相互作用または干渉しているのか？

機械学習とディープラーニングを適用して、変調識別に役立てることができます。まず、機械学習アルゴリズムを学習させるために特徴を手動で抽出するのに必要な時間と、ディープラーニング ネットワークを学習させるために必要な大規模データセットの準備に必要な時間のトレードオフを検討します。他に検討する点は、それぞれのアプローチの演算量の要件です。図 2 でこれらのトレードオフの関連が示されています。

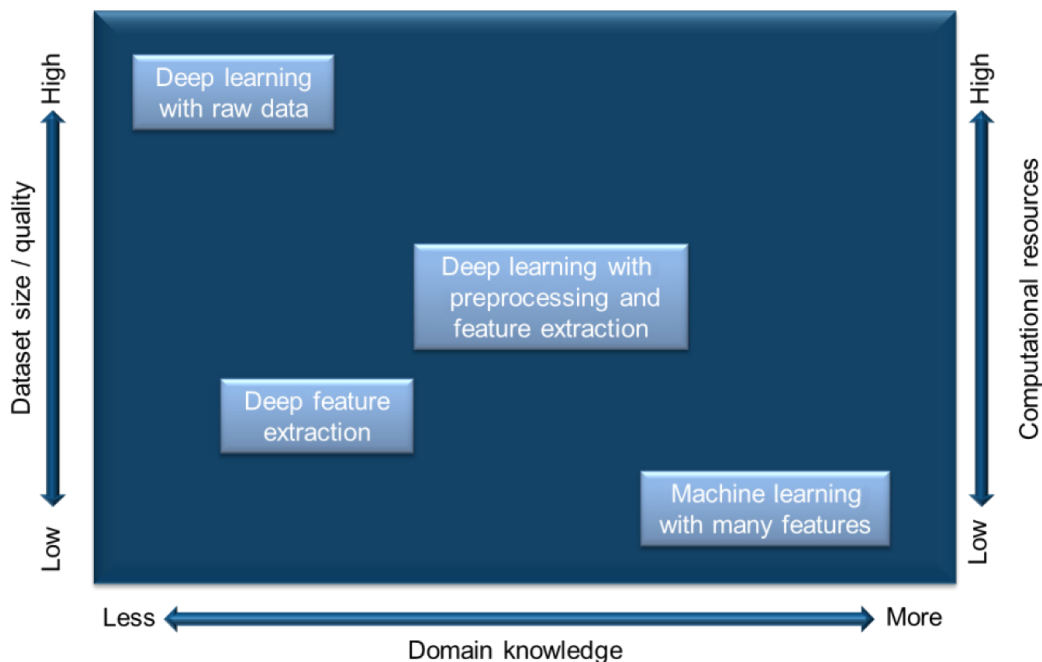


図 2. 学習データセットのサイズ、分野の専門知識、および必要となる演算リソースのトレードオフ

特徴を手動で抽出するのは時間がかかり、信号に関する詳細な知識が必要になります。一方で、ディープラーニングネットワークは最良の学習結果を得るには大量のデータを必要とします。ディープラーニングネットワークを使用する利点の一つは、前処理の作業と手動の特徴抽出が少なく済むことです。

自動運転とコンピュータビジョン全般に対する認識機能の要件の増加により、企業はやレーダーや通信など他の信号ベースのアプリケーションに活用できる画像や視覚ベースの学習に多大な投資を行っています。これは、生データまたは前処理されたデータがあるデータセットの両方の場合に当てはまります。

以下の例では、ディープラーニングネットワークが分類の観点から「重労働」を行うため、あなたは学習検証のためのデータセット要件を最善の方法で満たすことに集中できます。データはフィールド化されたシステムから生成できますが、このデータの収集とラベル付けは困難になることがあります。大規模データセットで、波形を追跡し、送受信のシステム結果を同期するときに、管理が難しくなることがあります。幅広い条件に渡るテストなど、地理的に同じ場所がないデータソースを協調させることも、さらに困難です。また、このデータの収集時またはファクトの後ラベル付けするには、グラウンドトゥールズが使用できないまたは信頼できないことがあるため、多大な労力が必要になります。

簡単に生成して管理してラベル付けできるため、合成データの使用がもう一つの選択肢になります。問題は合成データの忠実度が十分であるかです。次のユースケースでは、忠実度が高い合成データの生成が可能であることを確認します。

レーダーと通信波形を合成

前述のように、占有周波数スペクトルは混雑しており、通信システム、無線、およびナビゲーション システムなどの送信源がすべてスペクトルと競合します。テストシナリオを作成するには、次のさまざまな波形タイプを検討します。

- 矩形
- 線形周波数変調 (LFM)
- バーカー符号
- ガウス周波数シフトキーイング (GFSK)
- 連続位相周波数シフトキーイング (CPFSK)
- ブロードキャスト周波数変調 (B-FM)
- 両側波帯振幅変調 (DSB-AM)
- 片側波帯振幅変調 (SSB-AM)

これらの波形を定義すれば、それぞれの変調タイプの I/Q 信号をプログラムから多数生成することができます。各波形は固有のパラメーターを持っており、最終的な信号はモデルの忠実度を高めるためさまざまな障害で摂動されています。各波形に対し、パルス幅と繰返し周波数がランダムに生成されています。LFM 波形の場合、スイープ帯域とチャープ方向の生成がランダムです。バーカー波形では、チップ幅とチップ数がランダムに生成されています。すべての信号はガウスノイズで障害が加えられています。また、ランダムな搬送周波数を持つ周波数オフセットが各信号に適用されています。最後に、各信号はチャンネルモデルに渡されます。この例では、マルチパスライスフェージングのチャンネルが実装されていますが、他のモデルも代わりに使用することが可能です。

データは、学習ネットワークでの処理準備で生成されるときにラベル付けされます。

時間周波数解析手法を使用した特徴抽出

学習アルゴリズムの分類性能の改善に、よくあるアプローチは元の信号データがあったところに抽出された特徴を入力することです。特徴は入力データ表現を提供するため、分類アルゴリズムが区分を判別しやすくなります。

実際のアプリケーションでは、多くの信号が非定常になります。これは、周波数領域の内容が時間につれて変化することを意味します。特徴を抽出する有益な手法の一つは、分類アルゴリズムに入力可能な画像になる、時間周波数の解析です。時間周波数解析は、特定の周波数成分または断続的な干渉が、対象の信号に存在するかの識別に役立ちます。

多数の自動化手法が、スペクトログラムや連続ウェーブレット変換 (CWT) など時間周波数解析に使用可能です。しかし、他の手法に存在する漏れの影響がなく、高いスペクトル分解能力を提供するので、Wigner-Ville 分布 (WVD) が最初の良いアルゴリズムになります。

Wigner-Ville 分布は、時間によって変化する信号に役立つ、元データの時間周波数的ビューを表します。高分解能を時間と周波数の両方で使用できることが、類似する変調タイプを区別するのに役立ちます。しかし、WVD の性能は複数周波数成分からの交差条件により劣化します。代替手段として、smoothed pseudo WVD (SPWVD) を変調タイプのそれぞれに計算できます。図 3 に、1 つのデータセットでダウンサンプリングされた画像が表示されています。




図 3. レーダーおよび通信波形の時間周波数表現

これらの画像を使用して畳み込みニューラルネットワーク (CNN) を学習できます。ネットワークはデータセットの 80% を学習に使用し、10% をテスト用に、10% を検証用に使用します。

ディープラーニング ネットワークの設定と学習

ディープラーニング ネットワークの学習前に、ネットワークのアーキテクチャを定義しなければいけません。この例の結果は、画像分類のためのディープ CNN である、AlexNet を用いた転移学習を使用して取得されました。転移学習は、既存のニューラルネットワークを再訓練して新しいターゲットを分類するために使用されます。AlexNet は、デフォルトの設定で 1000 カテゴリーの分類を行うことができます。このデータセット用に AlexNet を調整するため、最後の 3 つの分類レイヤーを変更して、8 つの変調タイプのみ分類できるようにします。このワークフローは、SqueezeNet などのフットプリントが小さいネットワークでも実現できます。

CNN を作成すれば、学習を開始できます。データセットのサイズが大きいため、GPU またはマルチコアプロセッサでの処理の高速化をお勧めします。図 4 では GPU を使用して高速化された学習での、学習の進捗を時間関数として表しています。学習の進捗は、反復回数の関数と精度として表されます。検証の精度は 97% 以上です。

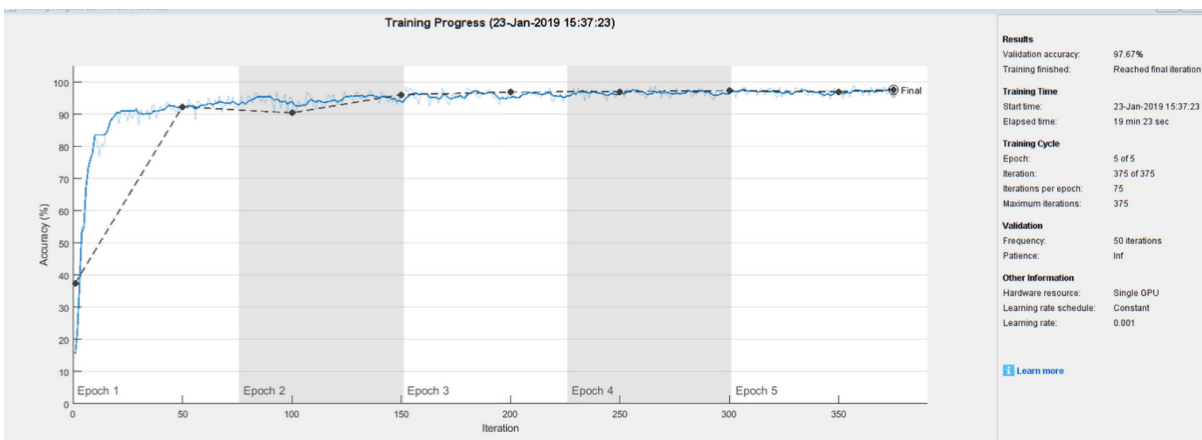


図 4. 処理の高速化に GPU を使用した学習の進捗

パフォーマンスの評価

前述の通り、生成されたデータの 10% はテストのため保存されています。8 つの変調タイプに対し、ネットワークへの入力は 99% 以上の B-FM、CPFSK、GFSK、バーカー、矩形、および LFM の変調タイプへと正確に分類されています。平均で 85% 以上の AM 信号が正しく識別されています。図 5 の混同行列で表されているとおり、DSB-AM の高いパーセンテージが SSB-AM へと、また SSB-AM が DSB-AM へと誤って分類されています。




図 5. 分類結果の混同行列

このワークフローのフレームワークにより、誤分類の調査が可能になり、ネットワークの学習プロセスの洞察を得ることができます。DSB-AM と SSB-AM は非常に近いシグネチャを持つため、ネットワークがこれら 2 つのタイプを正しく分類する難しさがこれで部分的に説明されます。連続ウェーブレット変換 (CWT) のようなその他の信号処理では、これら 2 つの変調タイプを、ネットワークで改善済みの分類結果でより明確に区別できるかもしれませんが。具体的には、CWT はより優れた多重解像度解析を提供します。これにより、信号の周波数の急激な変化にかかわるより良い情報がネットワークに提供されます。

次の例では、ネットワークにデータを入力する代替手法について見ていきます。また、テストフェーズで無線からのデータを使用する方法についても見ていきます。

I/Q データを用いた代替アプローチ

次の 11 の変調タイプ (デジタルが 8、アナログが 3) を含む新規データセットが最初に生成されています。

- 2 位相シフトキーイング (BPSK)
- 直交位相シフトキーイング (QPSK)
- 8 相位相シフトキーイング (8-PSK)
- 16 相直交振幅変調 (16-QAM)
- 64 相直交振幅変調 (64-QAM)
- 4 相パルス振幅変調 (PAM4)
- ガウス周波数シフトキーイング (GFSK)
- 連続位相周波数シフトキーイング (CPFSK)
- ブロードキャスト (B-FM)
- 両側波帯振幅変調 (DSB-AM)
- 片側波帯振幅変調 (SSB-AM)

ここでは、各変調に対して 10,000 フレームが生成されています。再び、図 6 に表されているように、ネットワークはデータセットの 80% を学習に使用し、10% をテスト用に、10% を検証用に使用します。




図 6. 波形タイプでラベル付けされたデータセットの分布

デジタルの変調タイプでは、8つのサンプルが記号の表現に使用されています。ネットワークは、複数の連続フレームではなく単一フレームに基づいて決定を行います。最初の例と類似して、それぞれの信号はチャンネルに加法的ホワイトガウスノイズ (AWGN)、マルチパス ライスフェージング、そしてランダムな時刻オフセットを渡しています。結果となる各変調タイプのチャンネル障害フレームが、ラベルに応じて保存されます。シナリオをより現実的にするために、ランダムな数のサンプルを各フレームの最初から削除し、トランジェント部を削除して、シンボルの境界に応じてランダムな開始点をフレームが持つようにします。図 7 では各波形タイプの時間および時間周波数表現が示されています。

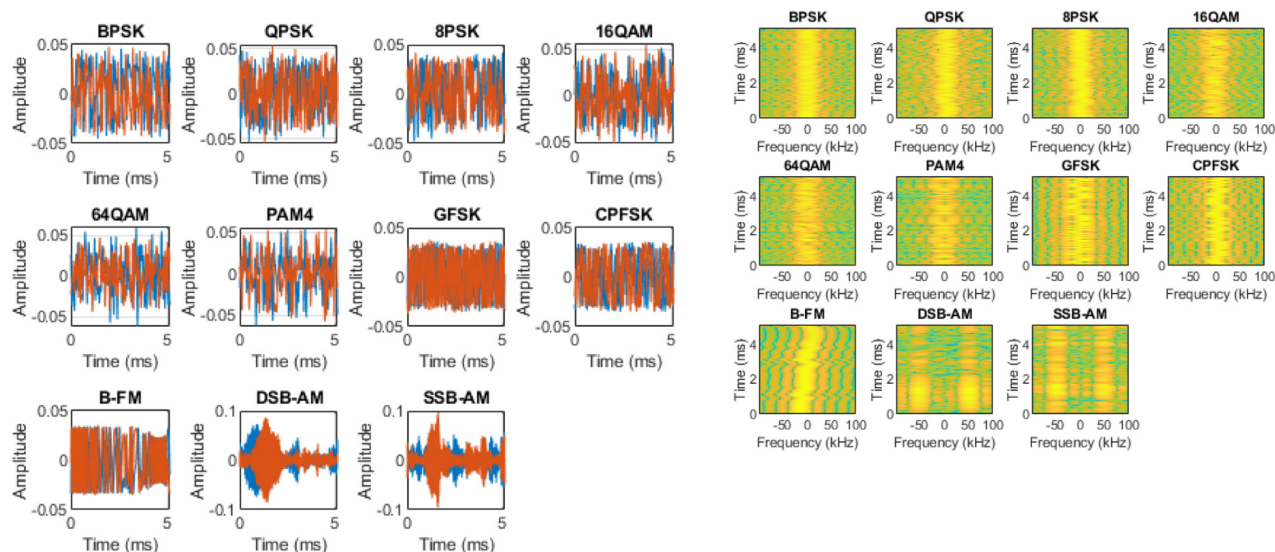


図7. 生成された波形の時間表現 (左) と対応する時間周波数表現 (右)

CNN の学習および結果の検証

この例では、6つの畳み込み層と1つの全結合層で構成されるCNNを使用します。最後の層を除く各畳み込み層には、バッチ正規化層、正規化線形ユニット (ReLU) 活性化層、および最大プーリング層が続きます。最後の畳み込み層の最大プーリング層は、平均プーリング層に変更されます。ネットワークの学習に、GPUを使用して処理を加速します。

前の例で、各画像は一つの画像に変換されました。この例では、前処理を行わず I/Q ベースバンドのサンプルを直接使用する代替のアプローチを実装します。

これを行うには、2次元配列の一部として I/Q ベースバンドのサンプル行を使用できます。ここでは、畳み込み層は同相および直交成分が独立に処理されます。全結合層でのみ、同相および直交成分の情報が統合されます。このアプローチにより 90% の精度が得られます。

このアプローチでのバリエーションは 3次元配列の I/Q サンプルとして使用するもので、同相および直交成分が配列の3次元目 (ページ) の一部になります。このアプローチは畳み込み層で I と Q のサンプルを均等に混合させ、位相情報を有効に活用します。

図8の混同行列に示されているように、I/Q データを行ではなくページとして表すことで、ネットワークが正確に 16-QAM と 64-QAM を区別、また QPSK と 8-PSK を区別する能力を劇的に向上させます。バリエーションは全体で 95% の精度を得られ、前のアプローチから 5% 以上改善させます。

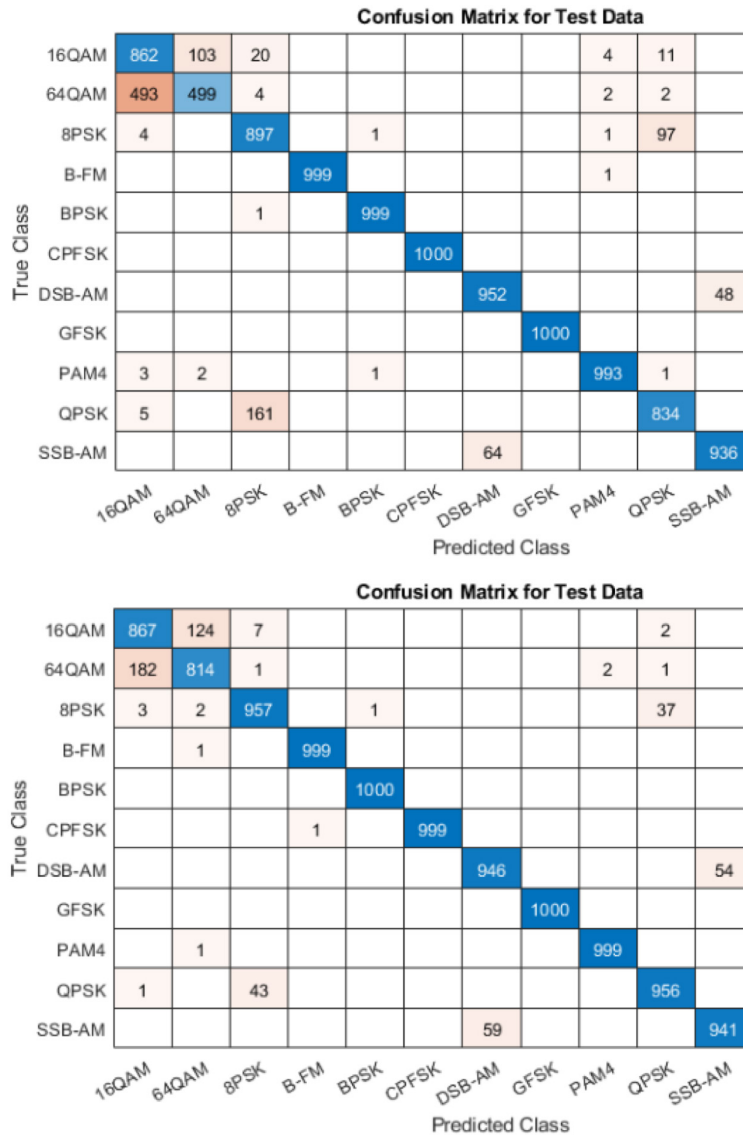


図 8. I/Q コンポーネントを行(上)として、またページ(下)として表した結果

SDR およびレーダーシステムのテスト

MATLAB で生成したデータのみを用いて、システムをテストすることが可能です。また、実信号を使用してシステムをテストすることもできます。これを実証するために、机上に設置された、2つの ADALM-PLUTO ソフトウェア無線機を利用し、通信波形を生成しました。図 9 にあるように、ネットワークは 99% の精度を実現します。これは机上の伝搬路の単純さから、MATLAB で複雑なチャネル劣化を含めて生成したデータを使用して得られた結果より良くなっています。このワークフローは、より現実的なシナリオから収集されたレーダーおよび無線データにまで広がります。



Confusion Matrix for Test Data

16QAM	99	1							
64QAM	7	93							
8PSK			100						
B-FM				98				2	
BPSK					100				
CPFSK						100			
GFSK							100		
PAM4								100	
QPSK									100
	16QAM	64QAM	8PSK	B-FM	BPSK	CPFSK	GFSK	PAM4	QPSK

True Class (rows), Predicted Class (columns)

図 9. ADALM-PLUTO を使用したソフトウェア無線システム (左) と対応する混同行列 (右)

図 10 には MATLAB と直接接続される Analog Devices の DemoRad プラットフォームを示しています。このレーダーシステムからデータを収集し、ベースバンドのデータを処理できます。この種のレーダーシステムを用いて、上記例を拡張し、データを収集、識別ができます。




図 10. Analog Devices の DemoRad レーダー評価基板

オブジェクトの分類

上述のように、レーダー波形はディープラーニングの手法を用いて識別できますが、それらを大きなレーダーシステムモデルの一部として使用することもできます。この種のシミュレーションでは、波形はアレイで送信され、伝播チャンネルを通過し、レーダーの探知範囲内にあるオブジェクトで反射され、レーダーで受信されます。次の例では、機械学習の手法を適用してレーダー探知範囲内のオブジェクトを識別する方法について見ていきます。

オブジェクトは、角周波数で変化する RCS パターンでモデル化できます。この単純な例では、シリンダーとコーンがレーダー探知範囲内のオブジェクトを表します。図 11 には異なるアスペクト角のシリンダーの RCS が表示されています。各オブジェクトのモーションモデルプロファイルの例と、単一データセットの対応するレーダーエコーも表示されています。このケースでは、運動を行う形状はボアサイトの周りで細かい振動を起こすと想定されその結果、アスペクト角はサンプルごとに変わります。




図 11. シリンダーの RCS (左) と、シリンダーとコーンのモーションモデルおよびレーダーエコーの例

また同様に他の形状から、コーンからそれたレーダーのエコーを生成することができます。このモデルとシミュレーションを基本として使用することで、さまざまな形状特性とモーションバリエーションでネットワークを学習するための多くのデータセットを生成できます。これは、現場のハードウェアに移動し、前のセクションで説明したのと同じ収集とラベル付けの課題に直面する前に、データを生成するより効率的な方法です。

学習アルゴリズムのマッチングパフォーマンスを改善するために、特徴抽出を使用して、分類アルゴリズムが異なるターゲットからの反射を簡単に区別させます。また、特徴は多くの場合元の信号より小さいため、学習に使用する演算リソースが少なくなります。

この例での信号の時間周波数特徴は、信号のウェーブレット パケット表現を使用しています。図 12 では、コーンとシリンダーの両方のウェーブレット パケットの特徴が表示されています。これらの特徴は、学習アルゴリズムが 2 つを区別するだろうという洞察を与えてくれます。具体的には、2 つの特徴の間には周波数コンテンツに違いがあります。




図 12. シリンダーとコーンのウェーブレット変換表現

シリンダーとコーンの反射での明らかな周波数の違いにより、周波数領域の測定を使用して信号を分類したほうが良いことがわかります。

抽出された特徴セットは、対象の反射ごとに 8 つの予測子により構成されています。元の時間領域の 701 サンプルのデータと比較して、これはデータの大きな削減です。ウェーブレット変換のレベル数を調整して、分類アルゴリズムのパフォーマンスを改善します。

図 13 に示される分類学習器を使用して、分類器を学習できます。学習データが読み込まれたら、アプリはデータセットに異なる学習アルゴリズムを適用し、分類の精度をレポートします。




図 13. 分類学習器アプリ

モデルが用意できたら、ネットワークは受信したターゲットの反射を処理し、分類を実行できます。これらのデータには算出された分類器に渡され、正確に 2 つの形状を分類できるか確認します。テストデータは 25 のシリンダーの反射と 25 のコーンの反射が含まれています。これらのシリンダーとコーンは、それぞれの形状に 5 つのサイズ、それぞれのサイズに 5 つのモーションプロファイルが含まれます。生成プロセスはデータの学習と同様ですが、特定の値はサイズ値と入射角値のランダム性により少し異なります。各形状のためのサンプル総数は、701x25 で結果の精度は 82% です。

学習データの量と品質を上げることで分類器のパフォーマンスを改善できます。さらに、特徴抽出プロセスを改善して、分類アルゴリズム内の各ターゲットの特性をさらに区別することができます。特徴毎に、最適な分類アルゴリズムが異なることがあることに注意してください。

より複雑なデータセットでは、畳み込みニューラルネットワークおよび長短期記憶 (LSTM) リカレントニューラルネットワークなどを使用したディープラーニングワークフローでパフォーマンスを改善できます。これらのワークフローは、以下のリンクで詳細に紹介されています。

まとめ

MATLAB により、時間周波数の特徴を信号から自動的に抽出できるようになります。これらの特徴を使用して、ディープラーニング ネットワークにより変調またはターゲットの分類を実行できます。チャンネル劣化を含んだ波形を生成、およびレーダーエコーを生成してラベル付けし、学習目的で、実データを追加、実データの置換が可能です。その後、ソフトウェア無線 (SDR) とレーダーからの実信号を使用して、このようなシステムの検証が行えます。

関連情報

ご紹介した例の詳細と MATLAB スクリプトについては以下をご覧ください。

- [ディープラーニングを使用したレーダー波形の分類](#) - 例
- [ディープラーニングによる変調の分類](#) - 例
- [機械学習を使用したレーダーターゲット分類](#) - 例