

# モデルベースのレーダー信号異常検出と歩行分析への応用

中央大学大学院・理工学研究科 田中 琉偉

## 1. 序論

データの大規模化や GPGPU による演算能力の向上に伴い、深層学習が様々な領域で活用されてきている。深層学習には大規模な学習データが必須であり、対象とする問題によってはその点が課題となってしまうことも少なくない。この問題に対応するため、シミュレーションデータ生成を用いることでデータ不足問題を解決する手法が提案されている[1]。シミュレーションデータ生成による学習は画像認識や音声認識、プラント最適化や原子分子などの分野において深層学習の適用範囲を広げることに貢献しており、異常検知など様々な問題に適用されている[2,3]。一方でレーダー信号に対するパターン認識の領域に着目すると、このようなアプローチによる研究は関連分野の論文誌を渉猟したが、殆ど報告されていない。レーダーデバイスは実社会で幅広く活用されており、レーダー信号のパターン認識においてシミュレーションデータを用いた学習の有効性を示せば、関連分野への貢献になると考えられる。

レーダー信号はレーダーに対する対象の移動速度・移動方向・反射面積・反射強度といった要素で観測値が変化する。これは対象が同じ動作をしていてもレーダーと対象との位置関係によって、得られる観測値が全く異なるということの意味する。一例として、人の歩行動作について3箇所から同時計測した場合の観測値の違いを図1に示す。図1はレーダーに対して図左下のように正面・斜め・横の3方向から測定した場合のスペクトログラムである。図より同じ動作をしていても、センサ上では全く異なる波形が観測されることがわかる。これは、ドップラーレーダーが対象のセンサ方向への移動速度を計測する特性上、得られる観測波形が観測地点によって異なるためであり、デバイスの設置位置を限定しない形で対象の動きを検出したい場合、あらゆる方向や高さか

らデータを計測する必要がありデータの調達に多大なコストを必要とすることを意味する。

このような背景から、本研究では学習データをシミュレーションデータから構築・学習させる手法の有効性について検証を行う。これにより、レーダーの設置位置を変えたとしてもシミュレーション空間でレーダー位置を変えてデータを生成・学習させることでデータ取得コストを減少させることが可能になる。そのため、当該デバイスの応用領域である医療や介護、軍事・セキュリティなど様々な領域の問題解決の一助となる可能性がある。

本研究では運動モデルの中でも最も複雑なものの一つである人の歩行動作を対象として、歩行モデルから生成されたシミュレーションデータをもとに、歩容の学習を行い、歩行の異常パターン検出を行った。異常パターンとしては本研究では「片足を引きずった状態の歩行」と「両手で荷物を持った歩行」の2パターンを検知対象とする。




図 1：3方向から同一動作を計測したときのスペクトログラムの違い

## 2. 提案手法

本節ではまず本研究で使用するマイクロ波ドップラーレーダーの原理を示し、その後今回対象とするヒトの歩行動作の数理モデルについて概説する。

### 2.1 マイクロ波ドップラーレーダー

マイクロ波ドップラーレーダーは送信波と受信波の周波数のずれや振幅を観測することで、対

象の移動速度や大きさを測定可能なデバイスである。センサの送信波を $v_s(t)$ とすると、送信周波数を $f_0$ 、初期位相を $o_s$ として $v_s(t) = A_s \cos \phi_s$ のように表せる。ただし、 $\phi_s = 2\pi f_0 t + o_s$ であり、 $A_s$ は送信波の振幅を表す。センサが電波を照射してから受信するまでの時間は次式で表される。

$$Tr(t) = \frac{2D(t)}{c} = \frac{2}{c} \left( l_0 + \int_0^t v(t) dt \right)$$

ここで $c$ は光速、 $D(t)$ はセンサと対象物の距離、 $l_0$ はセンサと対象物の初距離、 $v(t)$ は速度を表す。受信波は上式の遅延があるため、 $v_r(t) = A_r \cos \phi_r$ のように表せる。ただし、 $\phi_r = 2\pi f_0(t - Tr(t)) + o_s$ であり、 $A_r$ は送信波の振幅を表す。センサの出力信号はIQ検波とローパスフィルタにより

$$I(t) = \frac{A_s A_r}{2} \cos(\phi_s - \phi_r), Q(t) = \frac{A_s A_r}{2} \sin(\phi_s - \phi_r)$$

として得ることができる。ここで、 $\phi_s - \phi_r$ は以下の式で表すことができる。

$$\phi_s - \phi_r = 2\pi f_0 Tr(t) = \frac{4\pi f_0}{c} D(t)$$

上式より、観測される位相差は対象の移動速度 $D(t)$ に全て依存しており、これをモデリングすることで、観測波形をシミュレーションできることがわかる。

## 2.2 歩行動作のシミュレーションとドップラー信号データへの拡張

人間の歩行動作の数理モデルは様々なものが提案されており[4,5]、本研究は中でも歩容解析や運動生理学などの分野で提案された Boulic モデル[6]を用いて、それを拡張することによりドップラーレーダー上のシミュレーションデータを構築する。Boulic モデルを選択した理由としては複雑な数式・最適化に基づいていないことによる計算時間が短く、大量データ生成に向いているためである。動作モデルの詳細は非常に複雑であるため本稿では省略するが、詳細は[6]を参照されたい。

次に、歩行モデルからドップラー信号データを得る方法について概説する。厳密には体表面の移動速度を面積分して計算をする必要があるが、本研究では簡単のため、観測される波形は胴体や足・腕関節といった人体の中でも占める面積の大

きい部位が反射波では支配的であると仮定し、各部位に楕円体を仮定することで、レーダー反射面積(RCS)  $\sigma$ を次式により計算し、各部位の移動速度から計算されたドップラー周波数の電波強度を $\sigma e^{-4i\pi(d/\lambda)}$ の絶対値として信号をシミュレートした。ここで $d$ は体部位とレーダーの距離、 $\lambda$ は波長、 $a, b, c$ は楕円体の半軸、 $\theta, \rho$ はセンサとの垂直平面と水平面における角度である。

$$\sigma = \frac{\pi a^2 b^2 c^2}{(a^2 (\sin \theta)^2 (\cos \rho)^2 + b^2 (\sin \theta)^2 (\sin \rho)^2 + c^2 (\cos \theta)^2)^2}$$

以下の図は上記シミュレーションに基づきドップラーセンサ上の歩行動作の信号波形をシミュレーションしたスペクトログラムであり、横軸が時間、縦軸が周波数、色の明るさは電波強度を示す。図の結果は先行研究の歩行動作の実測結果とよく一致する。




図 2 : 歩行動作のシミュレーション結果

## 3. 検証方法

本研究では学習データをシミュレーションデータから構築・学習させる手法の有効性について検証を行うべく、異常歩行検出モデルを構築した。本節ではまず提案手法による異常歩行の検出方法を示し、その後検出時に用いた実測データ、既存手法による異常歩行の検出方法について紹介する。

### 3.1 提案手法による異常歩行の検出

本研究では提案手法の有効性確認のため、異常歩行検出モデルを構築する。前節で構築したシミュレーションモデルを用いて、様々な身長及び歩行速度の歩行パターンを 2,000 パターン生成し、それらをスペクトログラムに変換した画像データを学習データとして anoGAN, Autoencoder, CNN による異常歩行検出モデルを構築した。スペクト

プログラムの時間分解能は 0.1[s]とし、周波数分解能は 3.05[Hz]、学習に使用する時間窓は 1.5[s]としてそれを 0.1[s]ごとにずらしたものを学習データとした。その後、3.2 節で紹介する計測データを検証データとし、判別精度を確認する。なお、本研究はシミュレーションデータによるレーダーセンサにおけるパターン認識の有効性を確認するものであり、認識モデルに関しては上記 3 つのモデルに限定するものではないことは留意されたい。シミュレーションデータを構築し、対象とする問題に応じて適切な認識モデルを採用すべきである。

### 3.2 実験

本研究では、通常の歩行に対する異常歩行として、2 パターンの歩行動作を定義した。

1 つ目のパターンは荷物を持った状態での歩行動作であり、2[l]のペットボトル 6 本が入った箱を両腕で保持した状態での歩行動作とした。これは足の動作自体は通常の動作と変わらないが、両腕が固定されることによる違いを検知できるかを確認するためである。もう 1 つは引きずり歩行動作であり、片足を引きずった状態での歩行動作を計測した。

被験者は 8 名であり、通常歩行とあわせて 3 種類のパターンでそれぞれ 6[m]、2 回歩行した。それらを検証・比較用の実データとする。

本研究では InnoSenT テクノロジー社製のマイクロ波ドップラーレーダー IPS-155 (中心周波数 24.0[GHz]) を使用し、サンプリングレートは 50,000[Hz]で計測を行った。次節では、それぞれの結果について、提案手法と実データを用いた場合の認識精度について比較していく。

### 3.3 既存手法による異常歩行の検出方法

本研究では、対照実験として Spec-augment によってデータ拡張された実測データによる学習と異常検出を行った。データ拡張による学習用・検証用データは被験者 ID 単位で分割を行う。学習用データとしては、対象 ID の被験者の通常歩行時のデータのみを学習データとして用いる。これらのデータは、データ拡張による大量データ生

成を行った。本研究ではデータ拡張には前述の通り Spec-augment[7]を使用し、周波数軸上では連続した最大 20%目盛分のマスキングを、時間軸上では連続した最大 30%目盛分のマスキングを行うことをそれぞれ 2 回行った。検証用データとしては、学習用に用いた ID 以外の被験者の正常・異常歩行データを用いて異常歩行の判別を行った。検証を行う際は、交差検証を行う。

## 4. 結果

本節では提案手法の結果について、複数モデルで比較した結果を報告する。比較対象として、実データを用いたデータ拡張 (学習に用いる被験者数 7 人) による結果も掲載する。判別精度には F1 スコアを採用している。結果は表 1, 2 を参照されたい。

表 1: 引きずり歩行の検知精度

使用モデル	提案手法	データ拡張
1 層の Autoencoder	0.90	0.89
2 層の Autoencoder	0.90	0.51
1 層の NN モデルによる Ano-GAN	0.902	0.77
2 層の NN モデルによる Ano-GAN	0.343	0.75
2層による畳み込み層を加えた Ano-GAN	0.242	0.00

表 2: 荷物持ち歩行の検知精度

使用モデル	提案手法	データ拡張
1 層の Autoencoder	0.83	0.88
2 層の Autoencoder	0.85	0.68
1 層の NN モデルによる Ano-GAN	0.97	0.81
2 層の NN モデルによる Ano-GAN	0.72	0.51
2層による畳み込み層を加えた Ano-GAN	0.68	0.11
1 層の CNN モデル	0.67	0.63
2 層の CNN モデル	0.67	0.72

なお、CNN モデルの学習データには、通常時と異常時のデータ両方が必要になる。シミュレーションデータの学習時、荷物持ち歩行は両腕の動きを無くした状態の歩行として定義したが、一方で、引きずり歩行は通常の歩行とは大きく異なる動作であるため、Boulic モデルによるシミュレーションの再現は難しく、今回は、引きずり歩行での CNN を用いた検証は見送ることとした。

## 5. 考察

提案手法であるシミュレーションデータによる学習が、既存手法であるデータ拡張による学習よりも精度が高くなる傾向を確認でき、レーダー信号を用いたパターン認識においてもシミュレーションデータを利用することの有効性を確認できた。

今回は歩行動作を対象とした異常検知を行い、引きずり歩行と荷物持ち歩行の検知を行った所、どちらもシミュレーションデータによる AnoGAN による解析が最も精度が高い結果になった。一方でレーダー信号のパターン認識においては様々なタスクが想定できるため、分析目標やデータの特徴に応じて、使用する学習モデルを調整する事でより良い精度を追求することがデータ解析者に求められる。

また、シミュレーションデータによる CNN を用いた解析の精度が低い事が出来た。動作を対象としたレーダー解析ではスペクトログラムに変換して画像として解析する事が一般的とされているにもかかわらず、層の少ない簡単なニューラルネットワークモデルを用いた解析の方が高い精度となった。レーダー信号における解析において、ニューラルネットワークモデルを用いた方が有効である可能性が示唆される。

## 6. 結論

本研究は、歩行動作の異常検知を対象とし、レーダー信号における、シミュレーションデータを用いた動作異常検知が有効性について検証を行った。提案手法より、シミュレーションによるアプローチから実験機器や被験者を用意せずにデ

ータ取得ができ、データ取得のコスト削減が期待できる。また、数理モデルによるシミュレーションデータは、模範的な動作を再現するため、個人差が大きく反映されることはない。そのため、対象とする動作に個人差による影響がほとんど加わっていないデータを学習データとして扱えるため、学習時に異質な動作データを含めずに済むことも期待できる。

今後の展望としては、今回行った異常歩行検知以外にも有効であるかどうかは不明であるため、他動作を対象とした異常検知が今後の課題の一つである。加えて、シミュレーションデータの生成も今後の課題として挙げられる。今回は Boulic モデルをもとにシミュレーションデータを生成しているが、他動作におけるシミュレーションデータ生成は確立できていない状況である。実動作から新たにシミュレーションモデルを生成するには、その動作や特性を正確に理解することや各身体部位の動作が他身体部位に影響を与える場合はその影響具合も反映する必要が生じる。複雑なモデルは計算コストを高くするため、まずは簡易的な方法で生成する手段を模索する事も今後の課題である。

## 参考文献

- [1] 岡野原大輔, シミュレーターと深層学習. Nvidia HPC Week. 2021
- [2] Roberts, Mike *et al.* "Hypersim: A photorealistic synthetic dataset for holistic indoor scene understanding." Proceedings of the IEEE/CVF international conference on computer vision. 2021.
- [3] Hollingsworth, Scott A *et al.* "Molecular dynamics simulation for all." Neuron 99.6 (2018): 1129-1143.
- [4] Dorn, Tim W *et al.* "Predictive simulation generates human adaptations during loaded and inclined walking." PloS one 10.4 (2015): e0121407.
- [5] Thelen, Darryl G *et al.* "Using computed muscle control to generate forward dynamic simulations of human walking from experimental data." Journal of biomechanics 39.6 (2006): 1107-1115.
- [6] Boulic, Ronan *et al.* "A global human walking model with real-time kinematic personification." The visual computer 6 (1990): 344-358.
- [7] Park, Daniel S *et al.* "SpecAugment: A simple data augmentation method for automatic speech recognition." arXiv preprint arXiv:1904.08779 (2019).