

論文 深層学習を利用したサブテラヘルツ波によるコンクリート内部の鋼板および鉄筋のかぶり厚さの予測

小山 顕*1・倉品 吏玖*1・西脇 智哉*2・橋本 勝文*3

要旨：サブテラヘルツ波を用いた非破壊検査技術の測定結果に対して深層学習を適用し、コンクリート中に埋設された金属のかぶり厚さを予測する手法を提案した。具体的には、コンクリート内部にかぶり厚さを 10～40 mm まで変化させて鋼板と鉄筋を埋設した試験体をサブテラヘルツカメラにより測定し、かぶり厚さを予測するための画像解析を行った。その結果、鋼板の場合にはいずれのかぶり厚さでも平均して 80%以上の再現率で予測できる一方、鉄筋の場合はかぶり厚さが 20 mm までの場合に高い再現率を示した。これらの結果から、当該技術を用いたかぶり厚さの判別可能範囲を拡大することができる可能性が示唆された。

キーワード：深層学習、ニューラルネットワーク、非破壊検査、サブテラヘルツ波、かぶり厚さ

1. はじめに

近年、自動運転技術をはじめとしたさまざまな分野で機械学習や、機械学習の一種である深層学習が用いられている¹⁾。機械学習とは膨大な教師データを用いて算出した法則性や規則性を基に、未知のデータを回帰または分類する手法である。深層学習は機械学習の一種であり、特に多層のニューラルネットワーク (NN) が用いられる。これらの手法はコンクリート分野においても有効であり、例えば、機械学習を用いることでコンクリートの配(調)合から圧縮強度の予測が可能であることが確認されている²⁾。また、深層学習を用いることでモルタル系外装材や基礎コンクリートの画像からひび割れを高精度で検出可能であることが確認されている。当該研究で採用される畳み込み層は画像から特徴量を抽出する役割を果たし、ひび割れの検出にも有効であることが示されている³⁾。このような深層学習における画像解析では、人間の能力を上回る可能性があることが示唆されている⁴⁾。

ところで、鉄筋コンクリート構造物など社会資本の急速な老朽化に伴い、適切な調査・診断と維持管理の重要性が指摘されている。そのため、発展が著しい非破壊検査手法の1つとして、近年サブテラヘルツ波を用いた非破壊検査技術に関して多くの研究が行われている⁵⁾。後述するサブテラヘルツ波とは、光波の持つ直進性と電波の持つ透過性を兼ね備えた電磁波の一種である。このサブテラヘルツ帯域に適性を持つサブテラヘルツカメラを用いることにより、コンクリート内部に埋設された鉄筋をコンタ図として画像で得ることができることを確認している。しかし、コンクリート内部の鉄筋のかぶり厚さの増加に伴い鉄筋を目視で確認することが困難になり、

最大のかぶり厚さ 10 mm まで顕著に鉄筋を観測できることが示されている⁶⁾。しかし、日本建築学会「建築工事標準仕様書・同解説 JASS5 鉄筋コンクリート工事⁷⁾」では、鉄筋コンクリート構造物の設計かぶり厚さとして、いかなる構造部材でも 30 mm 以上が設定されている。そのため、現在の観測範囲では実構造物への適用が困難であり、当該技術を用いた非破壊検査の高度化が求められている。

以上の背景から、本論文ではサブテラヘルツ波によって得られる測定結果に深層学習を適用することで、コンクリート内部に埋設した鋼板および鉄筋のかぶり厚さを予測する手法を提案する。モデルを作成するアルゴリズムには NN を採用した。

2. 測定概要

本論文では、サブテラヘルツ波による反射を比較的容易に検出することができると仮定した鋼板を埋設した試験体による測定と、実構造物への適用を想定した鉄筋を埋設した試験体による測定を行った。

2.1 サブテラヘルツ波について

図-1 にサブテラヘルツ波の概要を示す。サブテラヘルツ波とは、周波数が 0.03～0.3 THz、真空中の波長では 1～10 mm (比誘電率を 6 と仮定したコンクリート中では 0.41～4.1 mm) の電磁波のことを指す。コンクリートを含む非極性物質に対する透過性が高く、電磁波レーダ等に使用されるミリ波に比べて直進性が高い性質を持つ。

2.2 使用材料と配(調)合

セメントとして普通ポルトランドセメント (密度 3.16 g/cm³, 比表面積 3140 cm²/g), 細骨材として砕砂 (表乾密

*1 東北大学 大学院工学研究科 都市・建築学専攻 (学生会員)

*2 東北大学 大学院工学研究科 都市・建築学専攻 准教授 博士 (工学) (正会員)

*3 北海道大学 大学院工学研究院 土木工学部門 准教授 博士 (工学) (正会員)

度 2.66 g/cm³) および陸砂 (表乾密度 2.62 g/cm³), 粗骨材として碎石 (表乾密度 2.68 g/cm³, 最大寸法 20 mm), 混和剤として減水剤 (密度 1.05 g/cm³), 空気量調整剤として AE 剤 (密度 1.05 g/cm³) を使用した。

本論文において使用したコンクリートの配 (調) 合を表-1 に示す。水セメント比は 55% とし, 細骨材・セメントを投入して空練りを 1 分行った後, 水, 混和剤および AE 剤を加えて 1 分練り, 最後に粗骨材を加えて 1 分練り混ぜを行った。スランブは 18 cm, 練り混ぜ温度は 22.0°C, 空気量は 4.8% であった。練り混ぜには螺旋アーム式強制二軸練りミキサ (60 L) を用いた。

作製した試験体の概要を図-2 に示す。高さ 100 mm, 長さ 400 mm の梁型試験体に用いられる型枠を使用することで, 鋼板を埋設した試験体 (以下, 鋼板試験体) および鉄筋を埋設した試験体 (以下, 鉄筋試験体) を作製した。内部の鋼板および鉄筋は, コンクリート表面からのかぶり厚さを試験体ごとに変化させながら埋設した。鋼板試験体はかぶり厚さごとに 4 体, 鉄筋試験体はかぶり厚さが 10, 20 mm および 30, 40 mm の組合せでそれ




図-1 サブテラヘルツの周波数帯域

表-1 配 (調) 合表 (kg/m³)

セメント	水	細骨材	粗骨材	減水剤	AE 剤
340	180	810	954	1.7	10.2 (g)




図-2 作製した試験体

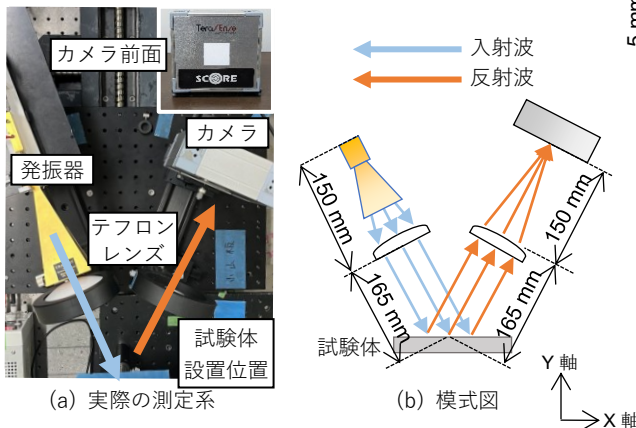


図-3 測定系の概要

ぞれ 1 体ずつ, 計 2 体作製した。鋼板試験体は, 鉄筋試験体よりもサブテラヘルツ波による反射を比較的容易に検出できると仮定して採用した。

2.3 測定概要

サブテラヘルツ波を用いた測定系を図-3 に示す。サブテラヘルツ波の発振器にはマイクロ波発生装置を使用し, 18~52 GHz まで発振可能な通倍器により増幅させて発振した。また, テフロンレンズを用いて試験体表面および検出器へサブテラヘルツ波が集光するように各装置の位置および角度を調整した。さらに, サブテラヘルツ帯に適性を持つ 16×16 の 256 個の素子を 2.4 cm 四方の中に 1.5 mm 間隔で搭載したサブテラヘルツカメラを検出器として使用した。Kobayashi らの検討⁹⁾によって, サブテラヘルツ波の測定結果が周波数に依存することが示されている。したがって周波数特性についても考慮するために, 30~50 GHz の周波数域を 1 GHz ずつ連続的に変化させることで測定を行った。また, 検出器に用いるカメラはそれぞれの素子によって感度がわずかに異なる。そのため, より正確な測定を行うためにはキャリブレーションを行うことで, 各素子の感度を一様に揃える必要がある。さらに, キャリブレーション時の微妙な差異が測定結果に大きく影響する。本論文では, はじめに発振をしない状態で, 最小値を定めるバックグラウンド補正を行った。その後, 各周波数を発振した状態で測定位置にアルミ板を置くことで最大値を定めるノーマライゼーション補正を行った。以上 2 つのカメラの素子の補正を行うキャリブレーションを複数回実行した。

図-4 にそれぞれの試験体の測定位置を示す。鋼板試験体は, 試験体の Z 軸方向の中央部分から Y 軸方向に 5 mm 間隔で測定を行った。また, 深層学習には用いない比較データとして, 鋼板を含まない位置でも測定を行った。鉄筋試験体は, 測定時に鉄筋の中心と 2 つのレンズの中心が Z 軸方向に一致する位置で測定を行った。この




図-4 試験体の測定位置

とき、試験体の Z 軸方向の中央部分から Y 軸方向に左右 1 cm および 2 cm の間隔をあけて測定した。鋼板試験体による測定も同様に、比較用データとして鉄筋を含まない位置からも測定を行った。また、試験体は恒温室内で乾燥させた後に測定を行った。

2.4 実験水準

実験水準を表-2 に示す。鋼板試験体と鉄筋試験体を測定に用いて、鋼板・鉄筋のかぶり厚さをパラメータとした測定を行った。このとき、それぞれの試験体のかぶり厚さは 10, 20, 30, 40 mm とした。

3. 深層学習の概要および構造

深層学習を用いた解析は、作成したデータセットに対してモデルを構築することにより実行される。このとき、モデルの精度は選定したアルゴリズムに依存する⁸⁾。

3.1 作成したデータセット

鋼板試験体および鉄筋試験体の測定位置、かぶり厚さおよび測定時に用いる周波数を変化させることでデータを取得し、データセットを作成した。さらに、第2章で述べたように測定データはキャリブレーションを行う環境の微小な差異に依存する。そのため、キャリブレーションを複数回行うことで、測定環境の微小な差異に依存しないようにデータセットを作成し、測定誤差の抑制を図った。結果として、鋼板試験体による測定では 1680 個のデータから構成されるデータセットを作成し、1260 個のデータを学習用データ、420 個のデータを試験用データとしてモデルの構築に使用した。鉄筋試験体による測定では 2100 個のデータから構成されるデータセットを作成し、1680 個のデータを学習用データ、420 個のデータを試験用データとしてモデルの構築に使用した。

3.2 作成した深層学習モデルの概要および構造

本論文では、コンクリート材料の分野に深層学習を適

表-2 実験水準

測定パラメータ	変数
鋼材形状	鋼板 (SPCC), 鉄筋 (D13)
かぶり厚さ [mm]	10, 20, 30, 40
周波数 [GHz]	30~50, 1 GHz ごと




図-5 NN の構造

用した研究において有効な言語の 1 つとされる NN を用いた⁸⁾。NN の基本的な構造を図-5 に示す。NN は、サブテラヘルツカメラにより得られる結果を入力する入力層および予測結果を確率で示す出力層と、その 2 つの層をつなぐ中間層から構成される。中間層は重みおよびバイアスから構成され、深層学習のモデルを作成するためにはそれぞれを最適化する必要がある。これらの重みおよびバイアスを複数回の学習を行うなかで連続的に更新することによって最適化され、モデルが作成される。

本論文で使用するモデルの構造を図-6 に示す。先の学習用データに対してサブテラヘルツカメラによって得られる測定画像を入力 (画像入力層) したのちに、畳み込み層などを用いることで特徴量の解析を行う。また、サブテラヘルツ波を用いた測定結果は周波数に依存するため、本論文では入力周波数の数値を入力した (周波数入力層)。以上の 2 つの入力層を結合 (入力結合層) し、ReLU 関数や Softmax 関数を活性化関数として用いることによりさらに学習を進める。最後に、多クラス分類に適性を持つ Categorical Cross Entropy を誤差関数に用いる。また、モデルによる出力は各かぶり厚さ 10 mm, 20 mm, 30 mm, 40 mm に対する予測確率で算出される。このとき最も予測確率が高いかぶり厚さが、深層学習のモデルによって予測したかぶり厚さとして選定される。式(1)に Categorical Cross Entropy を示す。

$$Loss = -\sum_i y_i \log z_i \quad (1)$$

ここで、 y_i : 正解を表すクラスベクトル、 z_i : モデルによる予測確率である。

4. 測定結果およびモデルの構築

4.1 サブテラヘルツカメラによる測定結果

図-7 に鋼板試験体における鋼板を含む位置からの測定結果の一部、および鋼板試験体における鋼板を含まない位置からの測定結果の一部を 5 GHz ごとに示す。実際の試験体のかぶり厚さ (以下、実かぶり厚さ) が 10 mm においては、鋼板を含まない位置からの測定画像と比較すると、30 GHz および 35 GHz で顕著に鋼板の存在を確認することができる。45 GHz および 50 GHz では、反射

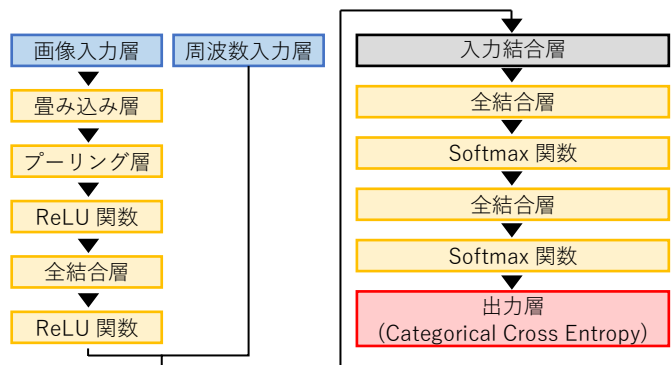
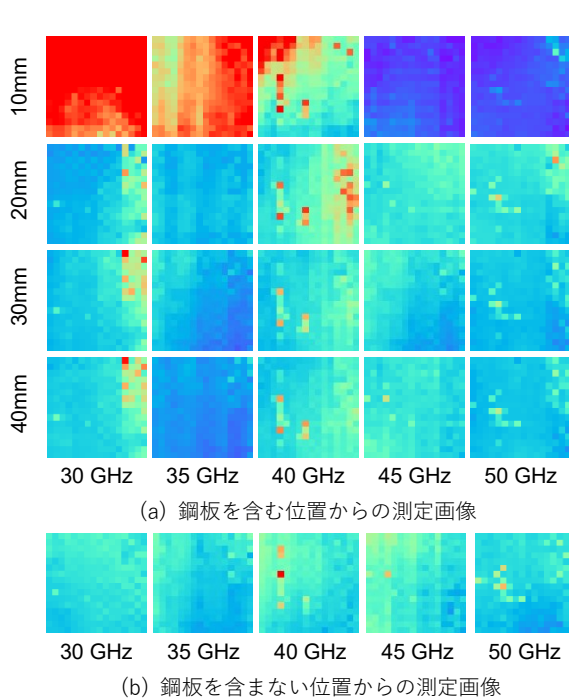


図-6 構築したモデルの構造



(a) 鋼板を含む位置からの測定画像

(b) 鋼板を含まない位置からの測定画像

図-7 鋼板試験体からの測定画像

— 学習用データ — 試験用データ

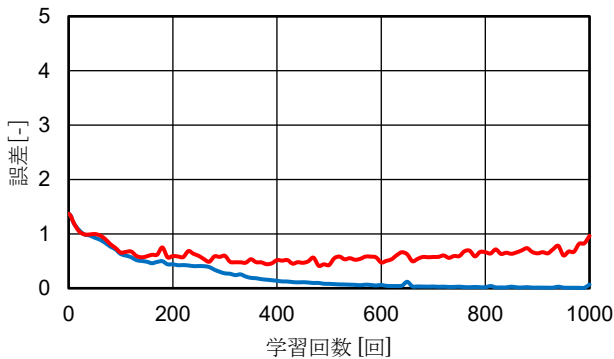


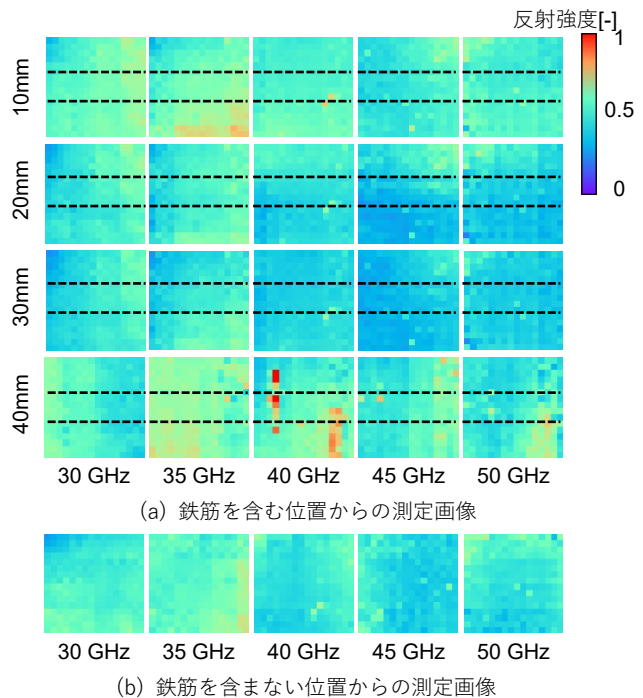
図-9 鋼板試験体のかぶり厚さを予測するモデルの学習曲線

表-3 鋼板試験体のかぶり厚さ予測

		予測かぶり厚さ [mm]				再現率
		10	20	30	40	
実かぶり厚さ [mm]	10	104	0	1	0	0.99
	20	0	84	8	13	0.80
	30	2	2	99	2	0.94
	40	0	18	16	71	0.73
適合率		0.98	0.83	0.85	0.84	
F 値		0.99	0.83	0.89	0.78	

強度が 0 に近い結果となることが確認できる。これは、コンクリート表面からの反射波と鋼板からの反射波が干渉を起こすことによって打ち消しあったためであると考えられる。実かぶり厚さが 20 mm 以上においては、鋼板を含まない位置からの測定画像と比較すると、反射強度において顕著な差を確認することはできなかった。これらの結果は、Kobayashi らの検討⁹⁾と同様の傾向を示している。

図-8 に鉄筋試験体における鋼板を含む位置からの測



(a) 鉄筋を含む位置からの測定画像

(b) 鉄筋を含まない位置からの測定画像

図-8 鉄筋試験体からの測定画像

— 学習用データ — 試験用データ




図-10 鉄筋試験体のかぶり厚さを予測するモデルの学習曲線

表-4 鉄筋試験体のかぶり厚さ予測

		予測かぶり厚さ [mm]				再現率
		10	20	30	40	
実かぶり厚さ [mm]	10	100	1	0	4	0.95
	20	9	96	0	0	0.91
	30	16	15	39	35	0.37
	40	15	10	44	36	0.34
適合率		0.71	0.79	0.47	0.48	
F 値		0.82	0.95	0.41	0.40	

定結果の一部、および鉄筋試験体における鉄筋を含まない位置からの測定結果の一部を 5 GHz ごとに示す。図中の破線は鉄筋の位置を示す。鉄筋を含まない位置からの測定画像と比較すると、いずれの実かぶり厚さにおいても内部の鉄筋を確認することはできなかった。これは、鉄筋位置における反射成分が微弱であったために、目視による鉄筋の存在が確認できなかったと予想される。これらの結果は、Kobayashi らの検討⁹⁾と概ね同様の傾向を示している。

表-5 周波数ごとの予測かぶり厚さの分布 (実かぶり厚さ : 30 mm)

		周波数[GHz]																				
		30	31	32	33	34	35	36	37	38	39	40	41	42	43	44	45	46	47	48	49	50
予測かぶり厚さ [mm]	10	0	0	4	0	5	1	0	1	2	1	2	0	0	0	0	0	0	0	0	0	0
	20	0	0	0	4	0	3	0	2	0	0	0	1	1	4	0	0	0	0	0	0	0
	30	5	5	0	1	0	1	5	2	0	0	0	4	4	0	0	4	0	4	4	0	0
	40	0	0	1	0	0	0	0	0	3	4	3	0	0	1	5	1	5	1	1	5	5

表-6 周波数ごとの予測かぶり厚さの分布 (実かぶり厚さ : 40 mm)

		周波数[GHz]																				
		30	31	32	33	34	35	36	37	38	39	40	41	42	43	44	45	46	47	48	49	50
予測かぶり厚さ [mm]	10	0	0	2	0	0	5	0	1	0	0	2	0	0	2	0	0	1	0	0	2	0
	20	2	0	0	0	0	0	0	1	2	4	0	0	0	0	1	0	0	0	0	0	0
	30	3	0	0	5	5	0	2	2	3	1	0	2	5	0	0	4	0	2	5	0	5
	40	0	5	3	0	0	0	3	1	0	0	3	3	0	3	4	1	4	3	0	3	0

4.2 鋼板試験体から取得した画像を用いた鋼板のかぶり厚さの予測を行うモデルの構築

図-9 にモデルを作成する際の学習曲線を示す。学習用データによる誤差は、学習回数が増加するのに従って誤差が小さくなり、およそ0に収束する結果となった。これは、コンクリート材料の分野に深層学習を適用した既往の研究⁸⁾と同様の結果となることが確認できた。また、試験用データの誤差は学習用データの結果とは異なり、学習終了時におよそ1付近に近づいていく結果となった。誤差の算出は、実かぶり厚さと作成したモデルの予測するかぶり厚さ（以下、予測かぶり厚さ）との一致度合いを、先の式(1)を用いて算出される。そこで、作成したモデルに対して試験用データを適用することで取得した予測かぶり厚さと実かぶり厚さを比較した結果を表-3 に示す。ここで、再現率とは作成したモデルによる予測かぶり厚さと実かぶり厚さの一致度合いを表し、適合率とは正しくモデルによって予測ができたかぶり厚さの一致度合いを表す。実かぶり厚さと予測かぶり厚さが一致したものは赤字で示している。いずれのかぶり厚さにおいても高い精度で予測可能であり、特に予測かぶり厚さが10 mmの再現率は99%と非常に高い精度で予測可能であることが確認できた。さらに、かぶり厚さが20 mmの場合でも、再現率は80%と高く、かぶり厚さの予測ができる可能性が示唆された。この結果より、Kobayashi らの検討⁹⁾では判定不可能であった実かぶり厚さ20 mmに関して予測が可能であることが期待される。また、実かぶり厚さが30 mm以上の場合においても予測できる可能性が示唆される結果となった。

以上の結果から、サブテラヘルツカメラによる画像を観察した場合、人間の視覚による実かぶり厚さの予測は困難であるが、深層学習を適用することで微弱な変化を読み取り、実かぶり厚さの予測ができる可能性が示唆さ

れる結果となった。

4.3 鉄筋試験体から取得した画像を用いた鉄筋のかぶり厚さの予測を行うモデルの構築

図-10 にモデルを作成する際の学習曲線を示す。先の鋼板のかぶり厚さを予測するモデルと同様に、学習用データによる誤差は、学習回数が増加するのに従って誤差が小さくなり、およそ0に収束する結果となった。一方で試験用データの誤差は、学習回数が増加するのに従って大きくなる結果となった。先の鋼板のかぶり厚さを予測するモデルとの比較を行うと、学習段階における誤差の上昇速度が大きく、学習終了時の誤差が非常に大きくなっていることが確認できる。作成したモデルに対して試験用データを適用することで取得した予測かぶり厚さと実かぶり厚さを比較した結果を表-4 に示す。同様に、実かぶり厚さと予測かぶり厚さが一致したものは赤字で示している。予測かぶり厚さが10 mmおよび20 mmの再現率はそれぞれ95%および91%と比較的高い精度で予測可能であることが確認された。これは、Kobayashi らの検討では判別不可能であった実かぶり厚さ20 mmに関して予測ができる可能性を示唆している。一方で、実かぶり厚さが30 mmおよび40 mmの再現率はそれぞれ37%および34%となった。この結果から、実かぶり厚さが30 mmおよび40 mmの判別ができなかったことによって図-10 に示す誤差の上昇が大きかったと考えられる。さらにこれらの結果は、実かぶり厚さが10 mmおよび20 mmの再現率、および鋼板のかぶり厚さを予測するモデルにおけるかぶり厚さ30 mmおよび40 mmの再現率と比較して劣る結果となった。これは、入射波の反射面の差異によるものであると考えることができる。鋼板表面で反射する場合は、反射位置に依存せず一律に反射すると予想される。しかし鉄筋表面で反射する場合は、鉄筋の曲率によって発振器からの入射波が反射位置に依存、お

よび乱反射すると考えることができる。これによって、かぶり厚さの予測に十分な反射強度を示す測定画像を得ることができたデータが限定的であったと考えることができる。濱崎らの検討⁹⁾では、サブテラヘルツ波によって得られるスペクトルを用いることで、かぶり厚さ 50 mm までの異形鉄筋を観測できる可能性が示されている。この検討では、鉄筋部分およびコンクリート部分での反射強度の平均値から差分反射強度を用いて評価している。これと同様に差分反射強度を用いることで、さらなる探査深度の向上の可能性がある。

試験用データに含まれる 420 個のデータのうち実かぶり厚さが 30 mm の 105 個のデータを、作成したモデルに対して適用することで算出した予測かぶり厚さを周波数帯ごとに詳細に分類した結果を表-5 に示す。105 個のデータには、測定に用いた周波数ごとに 5 個のデータが含まれる。この 5 個のデータは、上述の図-4 に示す位置での測定により収集した。実かぶり厚さと予測かぶり厚さが一致するデータを赤字で示している。この結果をそれぞれ単独の周波数として考える場合、モデルの予測精度が測定に使用する周波数に依存することが確認できる。特に、30 GHz、31 GHz、36 GHz は高い精度で予測可能であり、実かぶり厚さが 30 mm の予測に有効である可能性が示唆される結果となった。一方で、32 GHz や 50 GHz をはじめとする 10 種類の周波数では予測が困難であることが確認できる。

同様に、試験用データに含まれる 420 個のデータのうち実かぶり厚さが 40 mm の 105 個のデータを、作成したモデルに対して適用することで算出した予測かぶり厚さを周波数帯ごとに詳細に分類した結果を表-6 に示す。実かぶり厚さと予測かぶり厚さが一致するデータを赤字で示している。この結果から、31 GHz、44 GHz、46 GHz は高い精度で予測可能であり、実かぶり厚さが 40 mm の予測に有効である可能性が示唆される結果となった。一方で、30 GHz や 39 GHz をはじめとする 9 種類の周波数では予測が困難であることが確認できる。

以上の結果から、かぶり厚さの予測が可能である周波数および困難である周波数は、実かぶり厚さごとに異なる結果となった。しかし、これらの特定の周波数の情報を複合することで実かぶり厚さの予測の精度を向上することができる可能性が示唆された。すなわち、特定の周波数で予測が可能であるという結果に加えて、特定の周波数で予測が困難であるという結果を複合することで、実かぶり厚さの予測精度を向上することができると思われる。

5. 結論

本論文で得られた知見を示す。

- 1) コンクリート内部に埋設した鋼板のかぶり厚さの予測において、実際の試験体のかぶり厚さと作成した深層学習モデルによって予測したかぶり厚さは高い精度で一致する結果が得られた。
- 2) コンクリート内部に埋設した鉄筋のかぶり厚さの予測において、実際の試験体のかぶり厚さが 10 mm および 20 mm では、作成した深層学習モデルによって予測したかぶり厚さと高い精度で一致する結果となった。一方で、実際の試験体のかぶり厚さが 30 mm および 40 mm では、必ずしも作成した深層学習モデルによって予測したかぶり厚さと一致する結果にはならなかった。
- 3) 作成したモデルによって予測されたかぶり厚さを周波数ごとに分類した結果、かぶり厚さの予測を行う深層学習モデルを構築する場合、測定に用いる周波数をパラメータとして組み込むことが精度向上に寄与する可能性が示唆された。

謝辞

本研究の一部は、東北大学と東京電力ホールディングス株式会社 福島第一廃炉推進カンパニーとの共同研究「福島第一原子力発電所廃炉に資する研究・開発」において実施されたものである。ここに記し深謝する。

参考文献

- 1) 我妻広明：人工知能による運転支援・自動運転技術の現状と課題，計測と制御，Vol.54, No.11, pp.808-815, 2015
- 2) 小山頭，西脇智哉：機械学習を用いたコンクリートの圧縮強度の予測に関する基礎的研究，人工知能学会全国大会論文集，Vol.38, 2024
- 3) 千田紘之，高橋典之：深層学習を用いたコンクリート基礎および外装材の画像診断，コンクリート工学年次論文集，Vol.41, No.2, pp.1315-1320, 2019
- 4) 中村秀明：AI と技術の伝承，コンクリート工学，Vol.57, No.6, pp.415, 2019
- 5) 田邊匡生，小山裕：社会インフラのテラヘルツ非破壊検査，レーザー研究，Vol.47, No.1, pp.11-15, 2019
- 6) Kobayashi, C., *et al.*: Non-Destructive Testing of Reinforced Concrete Structures Using Sub-Terahertz Reflected Waves, *Developments in Built Environment*, Vol. 18, 100423, 2024
- 7) 日本建築学会：建築工事標準仕様書・同解説 JASS 5 鉄筋コンクリート工事，2022
- 8) Maherian, F. M., *et al.*: Machine learning-based compressive strength estimation in nano silica-modified concrete, *Construction and Building Materials*, Vol. 408, 133684, 2023
- 9) 濱崎仁ら：サブテラヘルツ波を用いたコンクリート中の鉄筋腐食に対する非破壊・非接触型評価手法に関する研究，実験力学，Vol.24, No.2, pp.50-58, 2024