

構造体コンクリート強度推定のための全国データベース整備と要因分析

Development of National Database and Factor Analysis for Strength Prediction of Structural Concrete

東京都市大学 准教授 佐藤幸恵

(研究計画ないし研究手法の概略)

近年、機械学習は様々な分野で活用されており、複雑な問題に対して解決を図ることを目的に利活用が進んでいる。機械学習は、機械が「訓練データ」や「学習データ」と呼ばれるデータを自動的に学習し、データの背景にあるルールやパターンを学習してその特徴から分析や予測を行う手法である。本研究では、材料品質の変動などの影響を網羅的に取り込んだ構造体コンクリート強度予測モデルを構築することを目的に検討を行った。これらは時間および実験コストを大幅に軽減し、副産物利用などの複雑化するコンクリートの品質管理を効率よく行うことを将来的な目標としている。

本課題では、具体的にこれまで蓄積した構造体強度発現のデータに材料や調合に関する要素を加えてデータベースを整備し、より複雑な問題を解析できる機械学習モデルに適用させることにより分析を試みた。

今回は機械学習アルゴリズムの一つであるランダムフォレストを用い、コンクリートに関する特徴量の中から使用材料の種類、品質、調合条件、施工条件を説明変数として設定し、標準養生供試体およびコア供試体の圧縮強度を目的変数として強度発現の推定を行った。また、設定する説明変数が目的変数に対してどの程度寄与したかを表す特徴量重要度を評価した。機械学習では、各説明変数がどの程度目的変数の予測に影響しているかがわかりづらくブラックボックス化しがちであるという問題がある。これに対し、説明変数と目的変数の関係を可視化することで、説明変数の変化が目的変数をどのように変動させるかを検証した。

使用したデータは、建築基準法 37 条 2 号に係る高強度コンクリートの国土交通大臣認定のために実施され、2000 年から 2014 年ごろまでに申請された実験結果のうち、レディーミクストコンクリート工場の単独申請のもの 367 件の性能評価申請書データを使用した。これらの実験で作製されている模擬供試体の例を図 1 に示す。実験では、標準養生供試体および模擬供試体から採取されたコア供試体、簡易断熱養生供試体などの強度発現を検討している。これらの実験データから圧縮強度および使用材料や調合条件、フレッシュコンクリートの性状、気温などの気温条件を抽出してデータベースを整備した。セメントについては、セメントメーカーに




図 1 模擬供試体の例 (JASS 5T-605)

提供を受けた鉱物組成比率と単位セメント量から各鉱物の質量として算出することでセメント種類の特徴量とした。目的変数を圧縮強度とした場合に用いた説明変数（特徴量）を表1に示す。

表1 使用した説明変数（特徴量）と目的変数

説明変数		目的変数					
セメント	セメント水比 C/W	細骨材	S絶対容積 [L/m ³]	標準28日強度 [N/mm ²]			
	C ₃ S単位置 [kg/m ³]		S表乾密度 [g/cm ³]		標準91日強度 [N/mm ²]		
	C ₂ S単位置 [kg/m ³]		S吸水率 [%]			コア28日強度 [N/mm ²]	
	C ₃ A単位置 [kg/m ³]		SFM (粗粒率)				コア91日強度 [N/mm ²]
	C ₄ AF単位置 [kg/m ³]		G絶対容積 [L/m ³]				
温度	当日平均気温 [°C]	粗骨材	G表乾密度 [g/cm ³]				
	模擬部材最高温度 [°C]		G吸水率 [%]				
	打込時空気量 [%]		GFM (粗粒率)				

なお、データベースの整備にあたり、表1に示す特徴量が欠損する場合があります。一揃いになるデータのまとまりをデータセットと呼ぶが、予測モデルに用いる特徴量のデータセットのうち、欠損値を有するデータセットが少なからず生じた。今回使用したランダムフォレストでは欠損値を扱うことが出来ないため、そのままの状態では機械学習に用いることができるデータセットが減少してしまう。そこで、データベース整備の過程で取得した各特徴量の統計値を用いて欠損値を補完することとした。例えば、骨材の密度が不明であるが岩石種類がわかっている場合は、同種の骨材の密度の平均値を代替値として入力した。また、打込み時空気量が欠損している場合は、目標空気量に対する所定の許容差で管理されていると判断出来るので、目標空気量で代替した。これらの作業によって、全367件（7122セット）あるデータセットのうち、186件（3257セット）をランダムフォレストに適用することができた。このデータセットを機械学習アルゴリズムに適用して圧縮強度の予測を行うこととした。モデルの学習にはランダムフォレストを使用し、使用言語は Python とした。データは Hold-Out 法によりデータセットを訓練データと検証データに分割した。

（実験調査によって得られた新しい知見）

図2に各圧縮強度に対する検証データの実測値と機械学習による予測値の関係を示す。

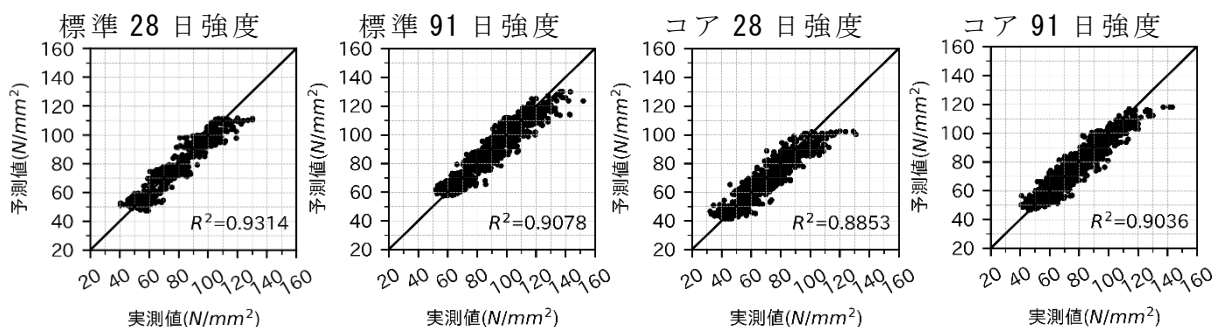


図2 検証データの実測値と機械学習による予測値の関係

図2より、いずれの圧縮強度に対しても R² 値は高い結果となり、高い相関性を有することが確認された。ただし、100N/mm² 超の超高強度領域では圧縮強度が高くなるほど相関性は低下すると考えられる。今回用いたデータベースは、ポルトランドセメント単体の結果のみであるため、実用的にはデータが少ないことが精度低下に繋がったと考察される。また、図3に機械学習によって求めた各特徴量の重要度を図3に示す。




図 3 各強度に対する特徴量重要度

図 3 より、いずれの強度に対しても最も重要度が高くなったのは C/W であった。これはセメント水比 (C/W) と圧縮強度の関係が直線式で表せるように、両者の関係の相関が高いことが影響していると考えられる。 C_4AF 単位量はセメント種類に関わらず鉍物組成比率が 8~12% であるため、鉍物の特性が影響したという意味合いよりも単位セメント量を表現したものと考えられる。同様に、 S 絶対容積は調合比率上、単位セメント量の大小と相関して単位量が決まってくる意味合いがあるため、単位セメント量との相関が考えられる。図 4 に、 C/W と C_4AF 単位量および S 絶対容積の関係を示す。図 4 に示すように、 C/W とそれぞれの特徴量は相関性が認められる。従って C_4AF 単位量の影響はセメント量に依存するものと判断され、 S 絶対容積は C/W が大きくなると相対的にセメント量が多くなり S 絶対容積が減少することを表していると考えられる。




図 4 C/W と特徴量の関係

これらの関係は機械学習のモデル精度にも影響を与えているため、 C_4AF および S 絶対容積を特徴量から除外して機械学習モデルを作成すると、モデルの精度が低下することから、単に C/W との相関以外の要素を含んでいる可能性が示唆された。

次に、図 3 より、セメントの主要鉍物 C_3S 、 C_2S 、 C_3A の単位量との関係をみると、標準養生 28 日強度では C_3S が上位となったのに対し、標準養生材齢 91 日強度とコア強度では C_2S が上位となった。これは、比較的早期の強度発現に対しては C_3S が強度発現に寄与し、長期的な強度発現や高温履歴を受けるような場合に低熱系のポルトランドセメントのほうが長期的な強度増進が有利であることなどと符合する。これらの結果より、機械学習によって得られた結果は、セメント鉍物の特徴が反映できていると解釈できる。また、セメント種

類が異なってもポルトランドセメントを単体使用した場合については、今回のようなデータ入力の方法でその傾向を十分に表現出来ることを確認した。

以上より、圧縮強度予測には、C/W とセメントの種類の影響が大きいことが機械学習からも得られたが、特徴量重要度では打込み時空気量と G 絶対容積、G 表乾密度等の粗骨材の品質に関わる要素が下位に続く。これらの特徴量の影響評価を PDP(partial dependence plots) を用いて分析を行った。PDP は特徴量を入力した際にその特徴量から得られる成果の関係をプロットするものである。図 5 に打込み時空気量の PDP を示す。




図 5 打込時空気量の PDP

図 5 より、いずれの圧縮強度においても、空気量が増加すると圧縮強度は低下するように機械学習していることがわかる。また、図 6 に粗骨材に関連する特徴量の PDP 結果を示す。




図 6 コア 91 日強度に対する粗骨材に関する特徴量の PDP

図 6 より、G 絶対容積は増加すると圧縮強度が低下する傾向を示した。これは、S 絶対容積との関係において、調合上は G 絶対容積が少ないと S 絶対容積が多くなることが考えられる。既往の研究では、高強度コンクリートにおいて、粗骨材絶対容積が増加すると圧縮強度が直線的に低くなることが報告されていることから、今回の結果も同様の特徴を表したと考えられる。表乾密度については岩石種類がそれほど多くないため、値のバリエーションが少なく、表乾密度 2.6-2.7 付近で大幅に圧縮強度が低下したように見えるが、データの少なさが影響した可能性があり、表乾密度の影響は不明確である。吸水率については、表乾密度と相関性が高いため、吸水率が大きい骨材では表乾密度が小さくなる関係に対して表乾密度と圧縮強度の PDP と逆の関係が示されたものと考えられる。粗粒率 GFM に対しても密度と同様に値のバリエーションが少なく相関性を読み取るには不十分と考えられる。通常は適正な粒度に調整した骨材が使用されるため、圧縮強度との関係に相関性を見出すことは難しいと考えられる。

以上より、管理用供試体である標準養生供試体強度や構造体コンクリート強度であるコア

強度に対して、機械学習で得られた予測結果は高い精度を示した。また、各種特徴量の重要度や影響要因を分析し、ブラックボックスモデルであるランダムフォレストを使用しても従来の知見と齟齬のない傾向を捉えた上で学習が出来ていることが確認できた。

機械学習結果により圧縮強度には C/W が他の要素に比べて卓越して影響することが確認され、高温履歴や長期的な強度発現を考慮すると単位セメント量やセメント種類が大きく影響することを明らかにした。今後は、混合セメントなどについても適用性を検討してより高精度な強度予測モデルの構築を行いたい。

(発 表 論 文)

・磯部亮汰，佐藤幸恵，山田義智，比嘉龍一：機械学習による構造体コンクリート強度発現の予測に関する基礎的研究，日本建築学会技術報告集，29巻，72号，2023.6（掲載決定）

・磯部亮汰，佐藤幸恵，山田義智，比嘉龍一：機械学習を用いた高強度コンクリートの圧縮強度予測，日本建築学会学術講演梗概集，pp.655-656，2022.7