

論文 機械学習を援用した収縮ひずみの終端値予測に対する短期間実測値の影響

岡崎 百合子*1・岡崎 慎一郎*2・浅本 晋吾*3

要旨：乾燥収縮試験における収縮ひずみの終端値 ϵ_{∞} は、配合や寸法、環境条件といった入手が容易な変数のみならず、骨材の比表面積など入手困難なものの影響も受けるため、これらの変数をすべて用いた ϵ_{∞} のモデルの構築は難しく、実務にも不向きである。本研究では、機械学習を用いた ϵ_{∞} の予測モデルの説明変数に、入手困難な変数の代替として、様々な変数の影響を包含している乾燥開始後から 28 日時点の収縮ひずみ ϵ_{28} の実測値を用い、その有用性を確認した。また、 ϵ_{28} に包含されない変数を適切に抽出し、それらの変数と ϵ_{28} を組み合わせた説明変数により、既存式に比して高い精度で ϵ_{∞} を予測できることを示した。

キーワード：乾燥収縮ひずみ、実測値、機械学習、終端値予測

1. はじめに

コンクリート構造物において、乾燥収縮がもたらす不具合は依然として報告されている¹⁾。建築学会および土木学会では、各設計コードにおいて、収縮ひずみの終端値 ϵ_{∞} を制限値として設け、照査を行うことが義務づけられているが、コンクリートの乾燥収縮は数年に亘って生じる現象であるため、設計のたびに終端値 ϵ_{∞} を実測で取得するのは現実的ではない。このため国内では、土木学会や建築学会式、国外では ACI209²⁾モデルや、CEB-FIBモデル³⁾、B4モデル⁴⁾等、様々な式が国内外で提案されているものの、いずれも予測精度は然程高くはない。その理由として、各式には、コンクリートの配合や試験体の寸法、環境条件等といった設計パラメータの影響が組み込まれているものの、骨材の比表面積等、乾燥収縮への影響は認識されている一方で取得が困難であるがゆえに説明変数として用いられていないパラメータの影響が一因として挙げられる。また、今後、新しく開発された結合材や、これまで利活用されていなかった混和材料をコンクリートの材料として用いる場合、既存式の適用範囲外になり、既存式ではさらに適切な予測が困難になると考えられる。

こうした課題に対して、設計パラメータのみならず、短期間の収縮ひずみの実測値を用いて ϵ_{∞} を予測する枠組みが建築学会の収縮ひび割れ制御指針⁵⁾によって示されている。短期間の収縮ひずみの実測値は、様々なパラメータの影響を包含していることからそれらの代替として用いることで ϵ_{∞} の予測が可能となると考えられる。著者らも、データに潜む複雑な支配機構を柔軟に抽出できる機械学習を援用し、乾燥開始後から 28 日時点の収縮ひ

ずみ ϵ_{28} の実測値を説明変数として使用することで将来の収縮ひずみの予測精度が改善することを確認したが、使用したデータが、7日間水中養生を行った100×100×400mmの角柱供試体を用い、温度20±2℃、相対湿度(60±5)%の環境条件で、JIS A1129に照らして計測された6か月時の収縮ひずみであったことから、予測対象は ϵ_{∞} ではなく6か月時の収縮ひずみであり、また、寸法や養生条件、環境条件は固定値であったため、配合のみをパラメータとした場合に留まっている。

本研究では、配合のみならず、寸法や環境条件等をパラメータとした国内外の収縮ひずみのデータ群に対して、入手が容易な設計パラメータと ϵ_{28} の実測値を用いて収縮ひずみの終端値 ϵ_{∞} を回帰する機械学習モデルを構築し、説明変数としての ϵ_{28} の使用がモデルの予測精度に与える影響を分析する。また、短期間の収縮ひずみの実測値を用いる既存式との予測精度の比較により、本研究で構築した機械学習モデルの優位性を検証する。

2. 対象データ

2.1 データ概要

データは、Bazantが収集したクリープ・収縮のデータ⁶⁾のうち、乾燥収縮試験時の全収縮ひずみ値を対象とする。そのデータには、それに付随する材料、養生、環境パラメータが含まれる。また、Bazantデータには、乾燥期間が比較的短い時点を含む経時的な収縮ひずみのデータが得られてるが、本研究ではひとまず、工学的に最も重要と考えられる全収縮ひずみの終端値 ϵ_{∞} を回帰対象とし、終端値に至るまでの時系列変動の回帰は今後の検討課題とする。なお、Bazantデータは、国内外の様々な文

*1 香川大学 イノベーションデザイン研究所 研究員 博士(工学) (正会員)

*2 香川大学 創造工学部 准教授 博士(工学) (正会員)

*3 埼玉大学 大学院理工学研究科 准教授 博士(工学) (正会員)




図-1 ϵ_{28} の実測値がない場合の線形内挿の概念図

献から収集されているため、試験期間が一様ではないが、1年以上の時系列データでは、その計測最終値の変動、すなわち計測最終値と1つ前の収縮ひずみの差は、平均値は 9μ 、標準偏差は 11μ 程度と僅かであったことから、乾燥期間が1年以上経過した時系列データの計測最終値を終端値 ϵ_{∞} とみなすこととした。また、これらのデータのうち、本研究で用いるデータは、養生時の相対湿度が98%以上のものに限定した。以上のデータ選定の結果、本研究で用いる終端値 ϵ_{∞} に関するデータは、国内外の24の文献⁷⁻¹¹⁾から収集され、そのデータ数は296となった。

なお、296ある時系列シリーズでは、 ϵ_{28} が必ずしも実測値として得られていないため、それらに対しては、図-1の概念図に示すとおり、乾燥開始後28日に対して直前と直後の実測値を線形内挿することで ϵ_{28} を算出した。

2.2 データに含まれる設計パラメータ

対象データのデータ数は296であり、各々のデータに材料条件、養生条件、環境条件の設計パラメータも与えられている。それらのうち、代表的なパラメータの頻度分布を図-2に示す。296のデータのうち、骨材セメント比A/Cは4~5周辺を中心に正規分布を呈する一方、水セメント比W/Cは0.4~0.6が92%と大半を占める。セメント種類は、普通セメントが80%と大半を占め、その他に早強セメント、高炉セメント等が含まれる。また、骨材の岩種については、具体的な記載がない「Others」が全体の81%となっている。よって、本対象データは、材料に関する変数の影響分析において、A/Cについては適しているものの、W/Cは不適である。また、骨材種類はデータの欠損が多い。

その他、形状の代表値であるV/Sは、15~45cmに分布し、養生条件である養生日数 t_{cur} はほぼ0~28日に分布する。環境条件としては、試験時の温度 T_{test} は18~23°Cに、試験時の相対湿度 RH_{test} は40~70%に分布する。

2.3 データに含まれる収縮ひずみ値

図-3に、本対象データに含まれる収縮ひずみ値の終端値 ϵ_{∞} と28日時の値 ϵ_{28} の頻度分布を示す。 ϵ_{∞} は、 -900μ ~ -1100μ を中心に、 -100μ から -1300μ まで分布しており、

ϵ_{28} は、 -400μ ~ -500μ を中心に、 -100μ から -700μ まで分布している。また、図-4に ϵ_{∞} と ϵ_{28} の相関図を示す。この2つの実測値は一定の相関が認められるものの、 ϵ_{28} が同程度のデータであっても、 ϵ_{∞} は 500μ 程度ばらつく。その一例として、図-5に ϵ_{28} が -280μ ~ -320μ である時系列データについて、収縮ひずみの経時変化を示す。同程度の ϵ_{28} であっても、乾燥開始28日以降の収縮ひずみの挙動は大きくばらつき、乾燥開始400日では、 -400μ 程度である一方、大きいものは -800μ 程度まで乾燥収縮ひずみが進行することが分かる。このように、 ϵ_{∞} と ϵ_{28} には一定の相関は認められるものの、 ϵ_{28} に包含されない変

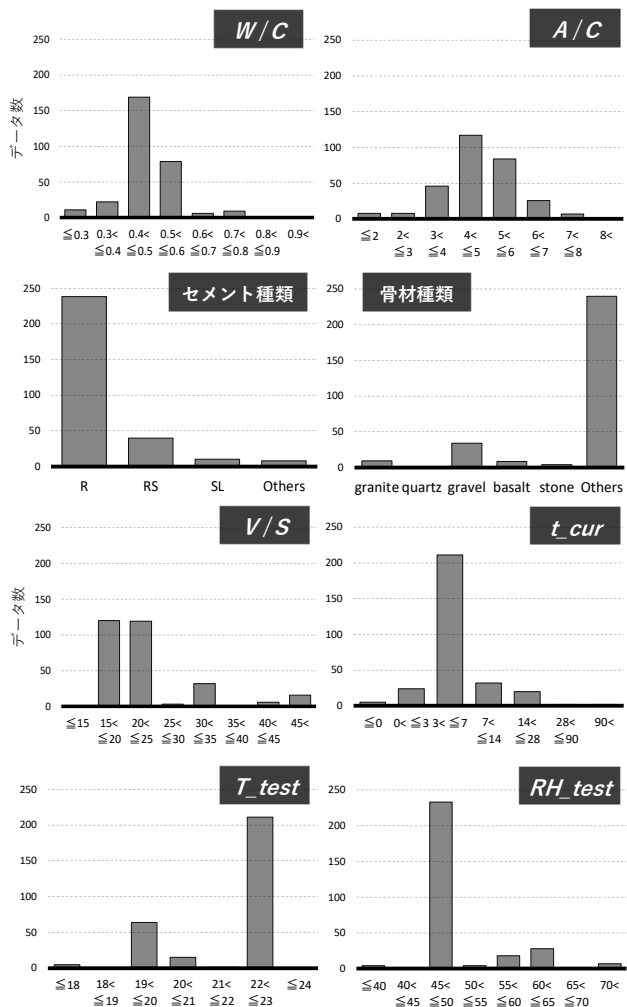


図-2 対象データにおける設計パラメータの頻度分布




図-3 対象データにおける収縮ひずみ値の頻度分布




図-4 対象データにおける ϵ_{28} の ϵ_{∞} の関係

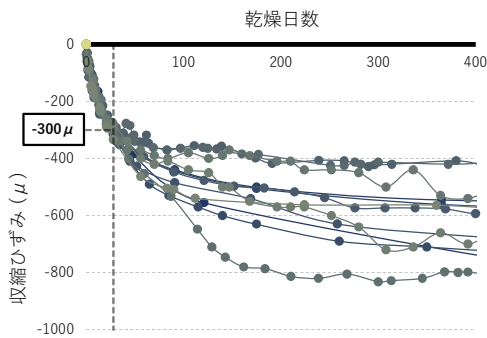


図-5 同程度の ϵ_{28} を有する収縮ひずみの時間変動

数の影響が残存し、 ϵ_{28} だけでは ϵ_{∞} の回帰が不十分である。そこで、このようなばらつきを入手が容易な設計パラメータで説明する機械学習モデルを次章で構築する。

3. 機械学習モデルの構築

3.1 概要

第2章に示したデータを対象に機械学習を実施し、乾燥収縮試験における全収縮量の終端値 ϵ_{∞} を回帰するモデルを構築した。モデルは、(a) 説明変数に28日時の収縮ひずみ ϵ_{28} を使用するケースと、(b) 説明変数に ϵ_{28} を使用しないケースの2つのモデルを構築し、この2つのモデルの予測精度を比較することで、 ϵ_{∞} の予測に対する ϵ_{28} の有用性を検証する。

学習アルゴリズムは、データの分布に偏りがある場合でも概ね傾向を柔軟に回帰できるガウス過程回帰¹²⁾を採用し、さらに、モデルが学習するデータ間の類似性の指標となるカーネル関数には、最も一般的に使用されている二乗指数カーネル¹³⁾を用いた。

高い予測精度の機械学習モデルの構築には、冗長的な説明変数を避けることが肝要¹⁴⁾であるため、モデル構築に先立って必要最低限の説明変数のセットを選択する必要がある。本研究では、冗長性を考慮して最低限の説明変数を選択できる逐次前方特徴量選択¹⁵⁾を採用した。

3.2 説明変数の選択

表-1には、対象データに含まれるパラメータを示す。

表-1 ϵ_{∞} の予測モデルの説明変数の候補


実測値	ϵ_{28} 28日時ひずみ				
配合	W/C 水セメント比	W 単位水量	C セメント量	A/C 骨材セメント比	A 骨材量
形状	V/S 体積表面積比				
養生環境	RH_{cur} 養生時 相対湿度	t_{cur} 養生日数			
試験環境	RH_{test} 試験時 相対湿度	T_{test} 試験時温度			

これらを説明変数の候補として、逐次前方特徴量選択を行い、説明変数の選択を行った。なお、表-1に含まれない収縮の影響要因として、骨材の岩種や比表面積、さらには混和材の種類や置換率等が挙げられるが、骨材の岩種については、2.2章で示したとおり、「Others」に分類されるものが大半であり、データが事実上欠損している。また、混和材の種類や置換率等のデータは、説明変数としては過度に細分化されたものになっており十分なデータ数を確保できないことに加え、それらを説明変数とした回帰モデルは、これまでデータが取得されていないような新材料に対しては適用範囲外となる。以上の理由から、本研究で候補とする説明変数は、入手が容易な設計パラメータのみとし、材料に関しては配合に関する変数に限定した。


逐次前方特徴量選択は、説明変数を1つずつ増加した暫定的なモデルを複数構築し、P値や決定係数、RMSE等を評価基準として暫定モデルを比較することで、最も優れた予測精度を有する説明変数のセットを選択する手法である。(a)説明変数に ϵ_{28} を使用するケースでは、表-2の全てのパラメータを候補として説明変数を選択し、(b)使用しないケースについては、表-2の ϵ_{28} 以外のパラメータから説明変数を選択した。

モデルの評価基準は、著者らが開発した検証方法LORO (Leave One Reference Out) 法¹⁶⁾により算出される二乗平均平方根誤差 (RMSE) とした。LORO法は、文献等からデータ D が収集された際、ある文献からのデータ D' を抜いたデータ $D \setminus D'$ をモデルに学習させ、モデルの予測精度を D' で検証する手法であり、データ数が限られ、偏りがあるデータ群に対しても、汎化性能を適切に評価するものである。

図-6に、逐次前方特徴量選択結果を示す。ケース(a)では、最初に ϵ_{28} が最も説明力が高い説明変数として選択され、続いて A/C 、 T_{test} 、 V/S を追加し、説明変数を4変数とした時点でRMSEが 82μ まで低減した。その後は、説明変数を追加してもRMSEは改善せず、むしろ説明変数の追加に伴ってRMSEが増加する傾向になった。



(a) 説明変数に ϵ_{28} を使用するケース



(b) 説明変数に ϵ_{28} を使用しないケース

図-6 特徴量選択結果

これは、冗長的な説明変数が追加されたことにより、データ内に含まれる誤差についてもモデルが学習してしまった結果、モデルの予測精度が低減したことが原因と考えられる。例えば、試験時の雰囲気における相対湿度 RH_{test} や水セメント比 W/C 、養生日数 t_{cur} は、乾燥収縮に影響を及ぼすことが広く知られているが、本パラメータを追加することによりモデルの予測精度は改善せず、むしろ低減している。これは、それらが ϵ_{28} に与える影響が、それまで選択された説明変数に既に含まれているためと解釈できる。よって、ケース(a)では、 ϵ_{28} 、 A/C 、 T_{test} 、 V/S の4つの変数が最適な説明変数の組み合わせであり、これらの変数を選択した。

ケース(b)では、ケース(a)と同様に、4つの変数追加時 (T_{test} 、 A/C 、 RH_{test} 、 V/S)において概ね最も低いRMSEを示したが、その値は 200μ と、ケース(a)で4変数を用いた際の値 82μ と比較して2倍程度大きい値となっている。この差は、説明変数候補の中にない、骨材や混和材等の影響が ϵ_{28} に含まれていることによると考えられる。なお、従来より ϵ_{28} の影響要因として知られている W や W/C が説明変数として選択されていない要因として、図-2に示すとおり、本研究の対象データの W/C は0.4~0.6が92%と大半を占め、本対象データにおいては配合による影響が大きくなかった可能性が挙げられる。一方で、著者らが以前実施した、JISA1129に照らして計測


された6か月時の収縮ひずみの回帰分析¹⁷⁾では W と W/C は機械学習モデルの説明変数として抽出された。そうした別のデータから得られた W や W/C の影響を事前知識としてモデルに付与したり、 W や W/C をパラメータとした長期の乾燥試験における収縮ひずみのデータをモデルに追加学習させたりする等して、今後、 W や W/C の影響を本研究で構築した機械学習モデルに組み入れる試みを検討したい。

以上より、ケース(a)とケース(b)に対し、それぞれ選択された最適な説明変数セットを用いたモデルを構築し、次章でその予測精度を比較することで、説明変数として ϵ_{28} の使用がモデルの予測精度に与える影響を分析する。


4. モデルの性能検証

4.1 28日収縮ひずみ実測値の有無によるモデル予測精度の比較

図-7に、ケース(a)およびケース(b)それぞれで選択された最適な説明変数セットを用いて構築したモデルにおける、 ϵ_{28} のモデル予測値と実測値との比較を示す。なお、機械学習は、学習に用いたデータによりモデルの予測精



(a) 説明変数に ϵ_{28} を使用するケース



(b) 説明変数に ϵ_{28} を使用しないケース

図-7 予測値と実測値の比較




図-8 予測値と実測値の比較

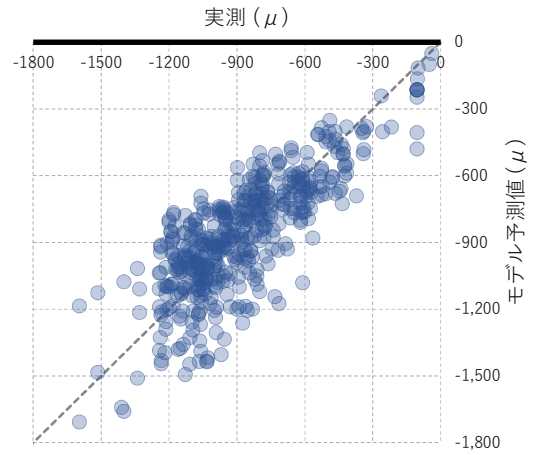


図-10 建築学会式の予測値と実測値の比較

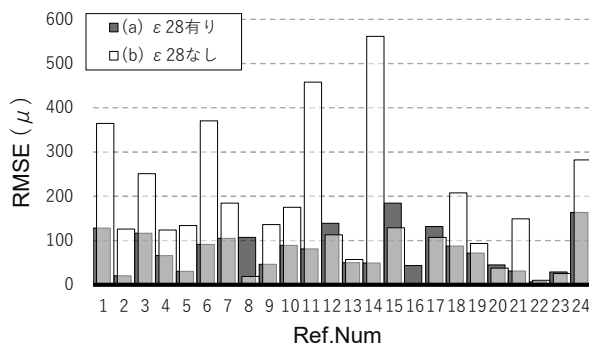


図-9 文献ごとの予測誤差による RMSE

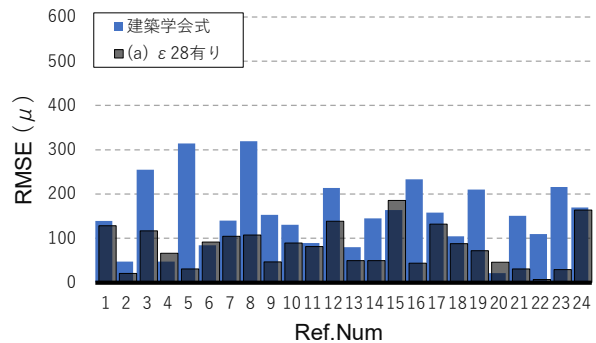


図-11 文献ごとの RMSE (建築学会式)

度を検証すると、予測性能を過剰に良好に評価する¹⁸⁾ことが知られている。このため、ここでのモデル予測値は LORO 法におけるモデル予測値、すなわち、各データに対し、そのデータが含まれる文献以外のデータを学習したモデルによる予測値とした。

図-7 の(b)の結果は、図-2 で示した設計パラメータのみでは ε_{∞} を十分に説明しきれないことを示している。ケース(a)では、モデルの予測値が実測を概ね良好に再現しているものの、特に実測値が -1200μ を超えるような領域に対しては、モデル予測値が実測を下回り、予測精度が低くなっている。この要因の特定のため、図-8 に図-7(a)を、図-9 に示す文献番号 24 のデータとそれ以外に色別で分けて示す。実測値が -1200μ を超す高収縮領域は、ほぼ文献 24 のデータであることから、LORO 検証時には本領域の学習が十分でなく、比較的低い予測精度になっている。

図-9 に、LORO 検証で得られた文献ごとの RMSE、すなわち、各文献をテストデータとした場合の予測誤差から算出した RMSE をケース(a)とケース(b)で比較して示す。ケース(a)は各文献の RMSE が 7μ から 185μ に、ケース(b)では、 10μ から 561μ に分布し、概ねケース(a)がケース(b)に比して低い RMSE を示し、 ε_{28} の使用が予測精度の改善に寄与していると考えられる。

4.2 既存式との予測精度の比較

最後に、収縮ひずみの実測値を用いて終端値 ε_{∞} を予測できる建築学会式⁵⁾と、本研究で構築した ε_{28} を説明変数に用いる機械学習モデルの予測精度を比較する。建築学会式は以下の式(1)で記述される。

$$\varepsilon_{sh\infty} = \frac{\varepsilon_{sh}(t_s)}{\left(\frac{t_s}{0.16 \cdot (V/S)^{1.8} + t_s}\right)^{1.4 \cdot (V/S)^{-1.8}}} \quad (1)$$

ここに、 $\varepsilon_{sh\infty}$: 収縮ひずみの終端値 (短期の乾燥収縮試験の実測値から算出する場合)、 $\varepsilon_{sh}(t_s)$: t_s における乾燥収縮ひずみの実測値、 t_s : 乾燥期間である。本研究で構築した機械学習モデルとの比較のため、 $t_s=28$ 日、すなわち、 $\varepsilon_{sh}(t_s) = \varepsilon_{28}$ とする。また、建築学会式は ε_{28} 以外には V/S のみを使用するが、本研究で構築した機械学習モデルは、 V/S に加え A/C および T_{test} を使用する違いがある。

図-10 および図-11 に、本対象データに対する建築学会式の予測値と実測値の比較と文献ごとのデータに対する予測誤差による RMSE を示す。図-10 と図-7(a) の比較により、建築学会式に比して、本研究で構築した機械学習モデルの予測精度が高くなっている。その理由として、建築学会式は簡潔な定式であることに加え、説

明変数が ε_{28} と V/S のみであり、本研究の機械学習モデルに比して少ないことから、この差が生じたものと考えられる。図-11に示す文献ごとのデータに対するRMSEにおいても、本研究の機械学習モデルのRMSEは建築学会式より概ね低くなっている。このことから、 ε_{∞} の予測には、 ε_{28} と V/S に加え、 A/C および T_{test} を説明変数と用いることで、予測精度が改善されると考えられる。

以上より、 ε_{∞} の予測において、短期間の収縮ひずみの実測値、すなわち ε_{28} を説明変数として用いることの有用性を確認した。また、 ε_{28} に包含されない説明変数を適切に抽出し、それらを説明変数に追加することで、既存式に比して高い予測精度を提供できることを示した。

本成果は、現時点でデータの蓄積されていない未知の材料に対し、比較的短期間の実測値を説明変数として組み込むことにより、高い精度での将来の性能評価を可能とすることを示唆している。

5. まとめ

本研究では、入手困難な変数の代替として、様々な変数の影響を包含する、乾燥開始後から28日時点の収縮ひずみ ε_{28} の実測値を用いて収縮ひずみの終端値 ε_{∞} を予測する機械学習モデルを構築し、その有用性を確認した。

- (1) (a) 説明変数に ε_{28} を使用するケースと、(b) ε_{28} を使用しないケースでそれぞれ収縮ひずみの終端値 ε_{∞} の予測モデルを構築し、予測精度を比較した結果、LORO検証におけるRMSEはそれぞれ(a) 82μ と(b) 200μ となり、 ε_{28} の使用が予測精度の改善に寄与していると考えられる。
- (2) モデル構築時、 ε_{28} に加え、骨材セメント比 A/C 、試験時温度 T_{test} 、体積比表面比 V/S を説明変数に追加することでモデルの予測精度が改善し、短期間の収縮ひずみの実測値を用いる既存式に比しても高い精度で ε_{∞} を予測できた。

謝辞

本研究はJSPS 科研費 23K03988 (代表：岡崎百合子)の助成を受けたものである。

参考文献

- 1) 市川市・第一庁舎の不具合等について：
<https://www.city.ichikawa.lg.jp/cus05/0000362620.html>
(閲覧日：2024年1月2日)
- 2) Rhodes, J. A. et al. : Prediction of creep, shrinkage, and temperature effects in concrete structures, 1982
- 3) Béton, C. E.-I. d. : CEB-FIP model code 1990: Design code, Thomas Telford Publishing, 1993
- 4) Wan-Wendner, R. et al. : Model B4: Multi-decade creep

- and shrinkage prediction of traditional and modern concretes, Conference: Computational Modelling of Concrete Structures - Proceedings of EURO-C 2014
- 5) 日本建築学会：鉄筋コンクリート造建築物の収縮ひび割れ制御設計・施工指針(案)・同解説, 2006
 - 6) Downloaded by <http://www.civil.northwestern.edu/people/bazant/> (閲覧日：2024年1月2日)
 - 7) Hindy, E. : Retrait et fluage des betons a haute performance, Universite de Sherbrooke, 1992
 - 8) Torben, C. et al. : Influence of Size and Shape of Member on the Shrinkage and Creep of Concrete, Journal Proceedings, Vol.63(2), pp. 267-290, 1966
 - 9) Mazloom, M., Ramezani pour, A. and Brooks, J. : Effect of silica fume on mechanical properties of high-strength concrete, Cement and concrete composites, Vol.26 (4), pp. 347-357, 2004
 - 10) Cenani, M.H., Sami, R, Paul, Z. and Amir, M : Creep and shrinkage behavior of high-strength concrete and minimum reinforcement ratio for bridge columns, PCI journal, Vol.55(3), 2010
 - 11) Bryant, A. H. and Vadhanavikkit, C. : Creep, shrinkage-size, and age at loading effects, Materials Journal, Vol.84(2), pp. 117-123, 1987
 - 12) Bishop, C. M. : Pattern Recognition and Machine Learning, Springer, 2006
 - 13) Rasmussen, C.E. : Gaussian processes in machine learning, Summer school on machine learning, Springer, pp. 63-71, 2003
 - 14) Samina, K., Tehmina, K. and Shamila, N. : A survey of feature selection and feature extraction techniques in machine learning, Science and Information Conference, pp. 372-378, 2014
 - 15) Guyon, I. and Elisseeff, A. : An introduction to variable and feature selection, Journal of machine learning research, Vol.3, pp. 1157-1182, 2003
 - 16) Okazaki, Y. et al. : Estimator for generalization performance of machine learning model trained by biased data collected from multiple references, Computer Aided Civil and Infrastructure Engineering, Vol.38, Issue 15, pp.2145-2162, 2023
 - 17) 岡崎百合子, 岡崎慎一郎, 浅本晋吾, 今本啓一：機械学習を援用したコンクリートの乾燥収縮に対する骨材の影響分析, コンクリート工学論文集, Vol.34, pp.37-46, 2023
 - 18) Xue, Y. : An overview of overfitting and its solutions, Journal of physics: Conference series, Vol.1168, pp. 022022, 2019