

# 生コン工場におけるデジタル技術を活用した コンクリートのフレッシュ性状予測システムの開発

市川翔太郎・玉滝浩司・高原幸之助

レディーミクストコンクリート工場における品質管理の効率化を目指し、機械学習、クラウド、アプリケーションなどのデジタル技術を活用して、出荷時におけるコンクリートのフレッシュ性状（スランプ、スランプフロー、空気量）を予測するシステムを開発した。本システムは、ミキサの電力負荷値、使用材料および配合などのデータを用いてリアルタイムにフレッシュ性状の予測を行うことで、即時かつ定量的に、コンクリートの品質を把握できる。加えて、本システムは、予測結果に基づきフレッシュ性状の変動を可視化し、工程検査データの入力による予測モデルの更新機能を有することで、コンクリートの更なる品質安定化に貢献する。

キーワード：工程検査、フレッシュ性状、電力負荷値、LightGBM、クラウド、アプリケーション

## 1 緒 言

近年、建設業全般における技術者の高齢化や若手人材の不足が深刻化している状況のなか、建設業の生産性向上が求められている。2024年には国土交通省が「i-Construction2.0」を策定し、建設現場の自動施工、BIM/CIM（3D モデリング）の活用、施工管理のリモート化などの施策により、2040 年までに建設現場の生産性を 1.5 倍以上に向上することを目指している<sup>(1)</sup>。レディーミクストコンクリート工場（以下、生コン工場）においても前述の懸念に対し、少ない人員で効率的に製造を行い、安定した品質のコンクリートを出荷することが事業を維持するための重要な課題となっている。生コン工場では、品質管理としてスランプ試験、スランプフロー試験および空気量試験を行っており、JIS Q 1011 附属書 A では、それらの試験を 1 回以上／午前、1 回以上／午後行なうことが規定されている。しかし、1 日あたりの出荷量が 300m<sup>3</sup>～700m<sup>3</sup>程度の生コン工場では、品質の安定化を目的として 1 日に 10 回～50 回程度の自主検査を行っているケースがあり、出荷前の品質試験に多くの時間と労力を割いているのが実情である。したがって、AI 技術の活用により定量的な判断、正確な予測ができるようになれば、これらの品質管理に関する作業の省力化に加えて、更なる品質の安定化や出荷の効率化にも貢献するものと考える。

そこで、著者らはこれまでに品質管理の省力化に

資するコンクリートと使用材料の品質予測技術の開発に取り組んだ<sup>(2)～(4)</sup>。本報では、実用化に向けて開発した出荷時におけるコンクリートのフレッシュ性状予測システムについて報告する。

## 2 予測モデルの作成

### 2.1 機械学習方法

フレッシュ性状予測システムを構築するにあたり、勾配ブースティング決定木（Gradient Boosting Decision Tree ; GBDT）を用いた機械学習手法の一つである LightGBM（Light Gradient Boosting Machine）を採用し、予測モデルの作成を行った。図 1 に LightGBM の概要を示す。LightGBM は、複数の弱学習器（決定木）を組み合わせて精度向上を図るアンサンブル学習のうちの勾配ブースティングによって分類や回帰

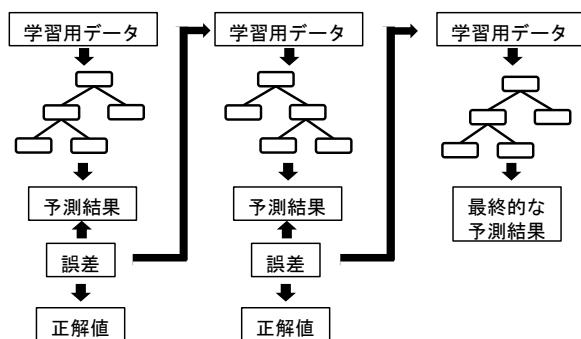


図 1 LightGBM の概要

を行う方法<sup>(5)</sup>である。勾配ブースティングとは、最初に訓練データの正解値と予測値の誤差を算出し、その誤差を修正するように次のモデルを繰り返し追加して、最終的に誤差が小さくなるように学習を進めるアルゴリズムである。それに加えて、Gradient-based One-Side Sampling (GOSS) や Exclusive Feature Bundling (EFB) の方法<sup>(5)</sup>を取り入れることで、より高速で高精度な学習を可能にしている。

予測モデルの作成には、Python の scikit-learn ライブラリを使用し、合計 8 つの初回モデルを作成した。表 1 に予測モデルの種類を示す。8 つのモデルを作成した理由は、管理区分（スランプ／スランプフロー）や強度区分（普通／高強度）によって学習用データ数の分布が異なり、これらの分布の違いによる予測精度の低下やバイアスを低減するためである。LightGBM は、Deep Neural Network (DNN) と比較した場合、学習用データの分布の影響を強く受けバイ

アスが大きくなることが報告されている<sup>(4)</sup>。また、LightGBM の主要なハイパーパラメータについては、全モデル共通のものは事前の検討で得られた最適な値を設定し、葉の最大数 (num\_leaves) だけは予測モデルごとに変化させて最適化を行った。

## 2.2 使用データ

表 2 に学習に使用した入力データを示す。本検証では、関東地区の生コン工場（1 工場）にて、2021 年 8 月から 2024 年 9 月までに実際に製造されたフレッシュコンクリートのデータ（運搬前のスランプおよび空気量であり、経時変化を見込まないデータ）を使用した。入力用のデータは、プラント操作盤やその周辺システムから受け取ったデータを前処理・加工することで取得できる。なお、目標スランプおよび目標空気量は、現場での受入時（荷卸し時）の値を意味しており、工場出荷時の目標値ではない。

表 1 予測モデルの種類（初回）

No.	管理区分	強度区分	予測項目	データ数	num_leaves	主要ハイパーパラメータ
1	スランプ 管理	普通 <sup>*1</sup>	スランプ	302,465	1,024	[全モデル共通] • metric : rmse • learning_rate : 0.05 • feature_fraction : 0.9 • bagging_fraction : 0.8 • bagging_freq : 5
2			スランプフロー	304,704	1,024	
3			空気量	304,704	1,024	
4		高強度 <sup>*2</sup>	スランプ	28,997	256	
5			スランプフロー	28,997	256	
6			空気量	28,997	256	
7	スランプ フロー管理	高強度 <sup>*2</sup>	スランプフロー	53,749	256	
8			空気量	53,612	256	

\*1 呼び強度 45 以下 \*2 呼び強度 45 超え

表 2 学習に使用したデータ

項目	区分	データの種類	特微量
入力	練混ぜ条件	練混ぜ量	練混ぜ量（立米数）
		製造時間帯	製造月、製造日、製造時刻（時間、分）、バッチ No.
		電力負荷値	初期値、最小値、最大値、最新値（図 2 中に示す点 P）
		電力負荷値から算出した統計量	範囲（最大値 - 最小値）、下降幅（最大値 - 終局値）、累計値、平均値、標準偏差、変動係数、中央値、第一四分位点、第三四分位点、尖度、歪度
		経過時間	練混ぜ時間、最大値到達時間、最大値からの排出時間
	使用材料 および配合	配合コード	呼び強度、目標スランプ、目標空気量、セメント種類（6 種類）、混和剤種類（6 種類）、細骨材種類（4 種類）、粗骨材種類（6 種類）、夏季における混和剤增量の有無
出力	正解データ	フレッシュ性状	スランプの実測値、空気量の実測値

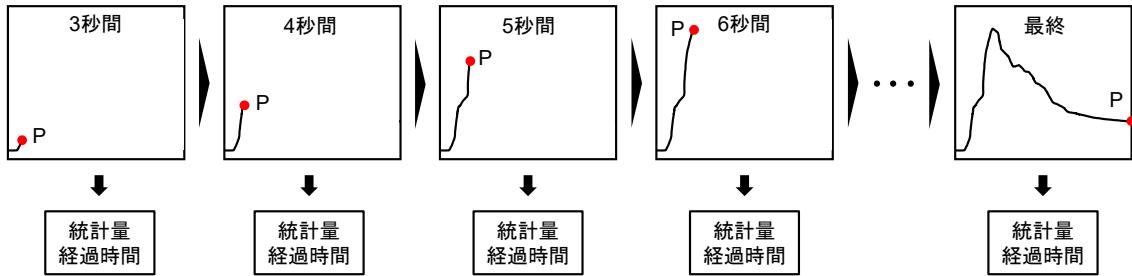


図2 電力負荷値のデータの前処理方法

### 2.3 データの前処理方法

練混ぜの最中にリアルタイムで予測を実行するシステムを構築するため、ミキサの電力負荷値データに前処理を施した。図2に電力負荷値データの前処理方法の概略図を示す。まず、データの取得開始から3秒後に、3秒間の電力負荷値データから表2に示す統計量データおよび経過時間データを算出した。その後、1秒ごとに電力負荷値のデータを追加して、統計量データおよび経過時間データについて算出する工程を練混ぜ終了まで繰り返し行い、1バッチ中に繰り返した回数分の予測値を出力した。なお、練混ぜ量データ、製造時間帯データおよび配合コードは、バッチごとに同一とした。

## 3 予測モデルの事前精度検証

### 3.1 検証方法

フレッシュ性状予測システムの構築に際し、事前に予測モデルの精度検証を行った。具体的な検証方法は、既報<sup>(4)</sup>を参照されたい。まず、精度検証用の予測モデルを作成するため、取得した入力データのうち、2021年8月から2023年12月までのデータ211,540サンプルを学習用データとして、LightGBMによる学習を行った。つづいて、未知のデータとして学習用データより後に製造されたフレッシュコンクリートのデータ42,127サンプルを使用して予測モデルの評価を行った。予測モデルの評価には、すべての季節が網羅できるよう2024年1月(冬期)、4月(標準期)、7月(夏期)のデータを採用した。

### 3.2 検証結果

図3にスランプの予測精度、図4に空気量の予測精度を示す。図中には、全サンプルの予測値および各実測値における予測値の中央値と、二乗平均平方根誤差(RMSE)を示している。RMSEが小さいほど、予測モデルの精度が高いと評価される。また、図中の点線はJIS A 5308に規定されている許容差であり、

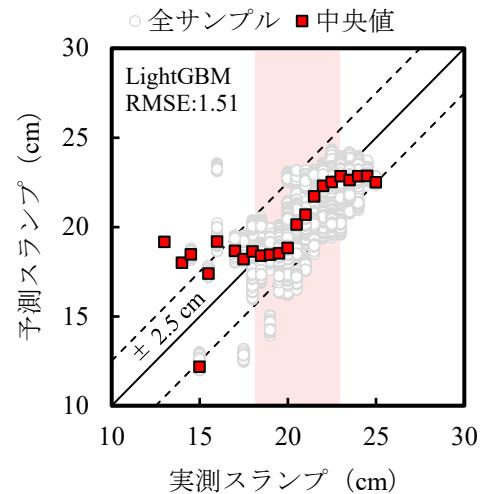


図3 スランプの予測精度

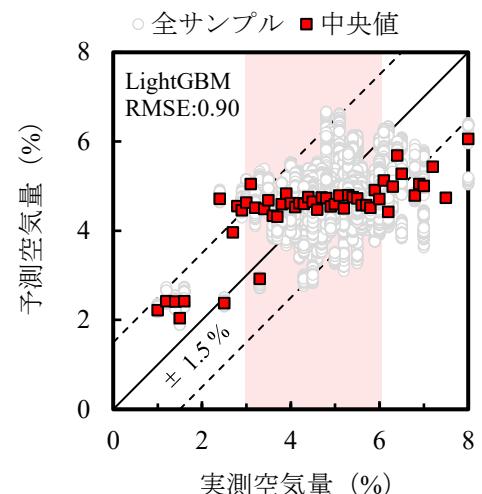


図4 空気量の予測精度

スランプは $\pm 2.5\text{ cm}$ 、空気量は $\pm 1.5\%$ の範囲を示している。RMSEをみると、スランプでは1.51、空気量では0.90であった。また、スランプの場合、中央値は、実測値が18cm～23cmの範囲では実測値と概ね一致しているものの、18cm未満では過大に、23cmを超える範囲では過小に評価された。一方、空気量の

場合、実測値が3.0%～6.0%の範囲に着目すると、中央値は4.5%前後の値を示していた。実測空気量が4.0%～5.0%であった学習データが、全学習データの約50%を占めており、データ数が少ない空気量（たとえば、3%、6%など）のコンクリートは、多数派のデータに影響されたものと推察する。

### 3.3 各特徴量の予測結果への貢献度

予測結果に対する各特徴量の貢献度を調べるために、SHAP (Shapley Additive exPlanations) ライブラリ<sup>(6)</sup>を用いて解析を行った。SHAPは、協力ゲーム理論で用いられるシャープレイ値<sup>(7)</sup>を機械学習に応用したものであり、特徴量ごとに計算されたシャープレイ値の符号と大小関係から、予測結果に対する各特徴量の貢献度を説明できるようにした手法である。貢献度の評価に際し、「寄与率」という指標を定義した。寄与率は、特徴量ごとにシャープレイ値の絶対平均を算出し、それらを全特徴量のシャープレイ値の絶対平均の総和で除した値とした。

表3に各特徴量の寄与率を示す。まず、スランプについてみると、目標スランプの寄与率が最も高い結果であった。通常、生産工場では、目標スランプに社内規格で定めた値を加味し、製造・品質管理を行っているため、目標スランプが出荷時のスランプと密接に関係することは明白である。次いで、寄与率は、製造時間帯に関するデータ（製造日、製造時刻、バッチNo.など）が20%程度、電力負荷値に関するデータ（最小値、累計値、初期値など）が10%程度、使用材料の種類が8%程度を占めていた。ここで、図5にバッチ経過ごとの電力負荷の初期値の推移を示す。図中には、配合および練混ぜ量が同一のコンクリートを製造した際の、電力負荷の初期値および実測スランプの推移が示されている。バッチ経過に伴い、実測スランプは横ばいに推移する一方で、電力負荷の初期値は小さくなっていることがわかる。すなわち、電力負荷値は製造時間帯によって異なるため、製造時間帯に関するデータや電力負荷の初期値、累計値の貢献度が上位になったものと考える。

次に、空気量についてみると、スランプの場合と同様の理由で、目標空気量の寄与率が18%程度と最上位であり、製造時期に関するデータの寄与率が36%程度と割合を多く占めた。また、上位25項目のうち、使用材料の種類の寄与率は14%程度、電力負荷値データの寄与率は12%程度であった。電力負荷値に影響する練混ぜ量は、両者とも上位であった。

表3 各特徴量の寄与率（上位25項目）

(a) スランプ

順位	特徴量	寄与率(%)
1	目標スランプ	50.40
2	バッチNo.	7.67
3	製造日_sin <sup>*1</sup>	3.05
4	製造日_cos <sup>*1</sup>	2.65
5	呼び強度	2.38
6	細骨材_1	2.12
7	時間_sin <sup>*1</sup>	1.90
8	最小値	1.89
9	練混ぜ量	1.73
10	分_cos <sup>*1</sup>	1.72
11	累計値	1.60
12	月_sin <sup>*1</sup>	1.59
13	初期値	1.58
14	月_cos <sup>*1</sup>	1.51
15	最大値-最小値	1.36
16	細骨材_2	1.36
17	混和剤_1	1.29
18	混和剤_2	1.22
19	セメント_1	1.17
20	分_sin <sup>*1</sup>	1.17
21	最大値-最終値	1.08
22	セメント_2	1.04
23	最大値	0.87
24	変動係数	0.84
25	最終値	0.81

(b) 空気量

順位	特徴量	寄与率(%)
1	目標空気量	18.26
2	製造月_cos <sup>*1</sup>	11.13
3	製造日_sin <sup>*1</sup>	5.95
4	呼び強度	5.83
5	バッチNo.	5.68
6	セメント_1	4.92
7	練混ぜ量	3.96
8	目標スランプ	3.20
9	製造日_cos <sup>*1</sup>	3.07
10	混和剤_1	2.96
11	時間_sin <sup>*1</sup>	2.90
12	最小値	2.71
13	初期値	2.57
14	分_sin <sup>*1</sup>	2.28
15	製造月_sin <sup>*1</sup>	2.26
16	最大値	2.20
17	分_cos <sup>*1</sup>	1.90
18	細骨材_1	1.85
19	混和剤_2	1.78
20	最大値-最小値	1.56
21	混和剤_3	1.43
22	変動係数	1.23
23	累計値	1.23
24	時間_cos <sup>*1</sup>	1.20
25	粗骨材_1	0.91

\*1 製造時間帯に関するデータは、周期性および連続性を有するため、正弦関数(sin)と余弦関数(cos)で表現した。

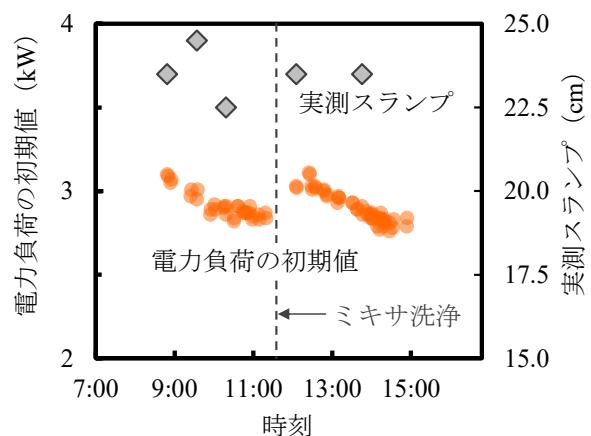


図5 バッチ経過ごとの電力負荷の初期値の推移

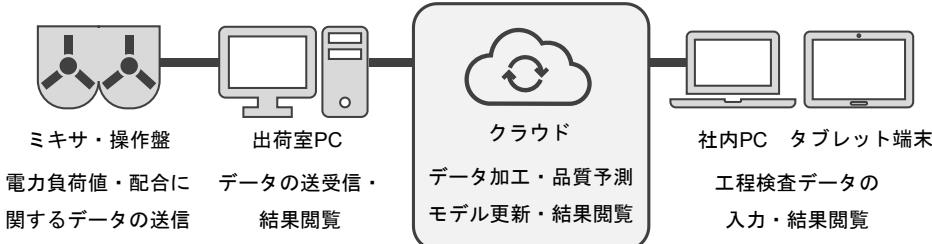


図 6 システム構成の概略

## 4 フレッシュ性状予測システム

### 4.1 システム構成

図 6 にシステム構成の概略を示す。フレッシュ性状の予測に必要な電力負荷値や配合に関するデータは、1 秒につき 1 ファイル生成される。これらのデータは、コンクリートミキサやプラント操作盤、その周辺システムから出荷室 PC に保存された時点で、クラウドに送信される。クラウドでは、受領したデータを予測モデルに入力する際の形式に合わせ、前述のデータの前処理を行った（2.3 参照）。前処理後のデータは、データベースに保存されたあと、予測モデルに入力されて予測結果が出力される。出力された予測結果は、入力データに紐づけられ、データベースに保存されるとともに、後述するアプリケーション画面に表示される。予測結果は、出荷室 PC、社内 PC およびタブレット端末などからクラウドにアクセスして確認することができる。また、後段で詳述するように、PC やタブレット端末から工程検査データを入力することができ、入力された工程検査データは、前処理後のデータおよび予測結果のデータと紐づけられ、データベースに保存される。工程検査データは予測モデルの更新に利用できる。

以降では、フレッシュ性状予測システムの各アプリケーション画面について説明する。

### 4.2 波形表示画面

図 7 に波形表示画面を示す。本画面では、コンクリートの練混ぜ中におけるミキサの電力負荷値を、リアルタイムに波形で表示する。併せて、配合および練混ぜ量が製造中のバッチと同一で、過去に工程検査の実績データが存在する場合、直近の電力負荷値および工程検査の実績データが表示される。製造中のデータと過去の実績データとの比較により、製造中のコンクリートのコンシステンシーや粘性を視覚的に判断することができる。また、スランプ、スランプフロー、スランプに対するスランプフローの



図 7 波形表示画面



図 8 変動管理画面

比、空気量の 4 項目の予測値がリアルタイムに表示される。これらにより、即時かつ定量的に製造中のコンクリートの品質を把握することができる。

### 4.3 変動管理画面

図 8 に変動管理画面を示す。本画面では、スランプ（もしくはスランプフロー）および空気量の変動が、予測結果に基づき表示される。また、表示条件は、配合、納入場所（図中の「出荷 No.」に該当）または目標スランプ別に絞り込みを行うことができる。加えて、表示対象のコンクリートの目標スランプお

より目標空気量を表示することで、製造目標との差異を確認することができる。このように品質の変動を可視化（全数検査）することにより、コンクリートの更なる品質安定化が図られる。さらに、予測結果に急激な変化が生じた場合には、製造上の異常（たとえば、骨材の粒度や表面水率の急激な変化、ミキサの不具合など）に素早く気づくことができ、適切な対処が可能となる。

#### 4.4 工程検査データ入力画面

図9および写真1に工程検査データ入力の画面とその様子を示す。本画面では、全バッチの予測結果が一覧で表示され、対応するバッチの工程検査結果が入力可能である。入力された工程検査データは、予測モデルの「追加学習」（もしくは「再学習」）に活用され、予測モデルを更新できる。「追加学習」とは、既存の予測モデルに新たなデータセットを追加して学習させることを指し、すべてのデータセットを使用して学習し直す「再学習」とは異なる。

追加学習は、予測モデルのバージョン、イテレーション数 (num\_boost\_round) および早期停止ラウンド数 (early\_stopping\_round)などを指定することで実行される。また、予測モデルの更新に要する時間は、700件（約20バッチ分）の新たなデータセットを追加学習する場合で10分程度、30万件のデータセットを再学習する場合で90分程度であった。したがって、本システムで採用したLightGBMの手法により追加学習を行うことで、当日の工程検査結果が予測モデルに即時に反映され、予測精度の改善を図ることができる。なお、追加学習後に予測精度が悪化する場合には、更新以前の予測モデルにロールバックすることが可能である。

## 5 結 言

生コン業界におけるデジタル活用と生産性向上を推進するため、フレッシュ性状の予測システムを開発した。本システムは、即時かつ定量的に、コンクリートの品質を把握することができ、コンクリートの更なる品質安定化に資するものと考える。今後は、継続したデータ収集・分析や実証試験を通して、予測モデルの性能向上、少数派データへの対処、省力化効果の検証などの課題を着実にクリアし、本システムの実用性を評価していく。生コン業界の持続的な発展のため、こうした取組みによって品質管理のあり方についての議論が活発になることを期待する。

推論結果一覧															
バッチ	出荷No.	日付	配合コード	練混ぜ量	基準	予測SL	予測SR	予測AR	実測SL	実測SR	実測AR	CT	AT	台数	表示
1	1	2025/02/13 07:05	1234567890	2.25	123	20.1	40.9	5.4	20.5	41.5	5.7	22	24	1	>
2	1	2025/02/13 07:06	1234567890	2.25	123	20.1	36.9	5.6	20.5	41.5	5.7	22	24	1	>
3	1	2025/02/13 07:10	1234567890	2.25	123	20.2	40.3	5.2							>
4	1	2025/02/13 07:11	1234567890	2.25	123	21.5	38.5	5.3							>
5	1	2025/02/13 07:12	1234567890	2.25	123	20.2	39.5	5.3	21.0	41.0	5.2	22	24	3	>
6	1	2025/02/13 07:13	1234567890	2.25	123	20.8	40	5.5	21.0	41.0	5.2	22	24	3	>
7	1	2025/02/13 07:18	1234567890	2.25	123	21.5	38.9	5.6							>
8	1	2025/02/13 07:19	1234567890	2.25	123	21.6	39.3	5.5							>
9	1	2025/02/13 07:20	1234567890	2.25	123	20.3	40	5.1	21.5	42.0	5.4	22	24	5	>
10	1	2025/02/13 07:21	1234567890	2.25	123	21.9	37.7	4.8	21.5	42.0	5.4	22	24	5	>

図9 工程検査データ入力画面



写真1 工程検査データ入力の様子

## 参考文献

- (1)国土交通省ウェブサイト：「i-construction 2.0～建設現場のオートメーション化～」、<https://www.mlit.go.jp/tec/constplan/content/001738240.pdf>、p.1-20 (2024)
- (2)市川翔太郎、板橋庸行、玉滝浩司、高原幸之助：「AIを活用したレディーミクストコンクリートと材料の品質予測」、セメント・コンクリート、No.918、p.8-13 (2023)
- (3)市川翔太郎、瀬川実暉、玉滝浩司、高原幸之助：「骨材粒度の予測性能に及ぼす画像処理方法の影響」、コンクリート工学年次論文集、Vol.47、No.1、pp.1914-1919 (2025)
- (4)瀬川実暉、市川翔太郎、玉滝浩司、高原幸之助：「ミキサの電力負荷値を使用したコンクリートのフレッシュ性状予測における機械学習方法の検討」、コンクリート工学年次論文集、Vol.47、No.1、pp.1920-1925 (2025)
- (5) Guolin Ke, Qi Meng, Thomas Finley, Taifeng Wang,

Wei Chen, Weidong Ma, Qiwei Ye, Tie-Yan Liu:  
“LightGBM: A Highly Efficient Gradient Boosting Decision Tree”, 31st Conference on Neural Information Processing Systems (NIPS 2017), p.1-9, (2017)

(6) Scott Lundberg, Su-In Lee: “A Unified Approach to Interpreting Model Predictions”, 31st Conference on Neural Information Processing Systems (NIPS 2017), p.1-10, (2017)

(7) Lloyd S. Shapley: “A Value for n-person Games”, Princeton University Press, Vol.2, No.28, pp.307-317, (1953)

---

市川翔太郎・いちかわ しょうたろう

研究所 コンクリート研究室

生コン・特殊コンクリート 研究員

玉滝浩司・たまたき こうじ

研究所 コンクリート研究室

生コン・特殊コンクリート グループリーダー

高原幸之助・たかはら こうのすけ

研究所 コンクリート研究室 室長