

AI活用でさまざまな電池に対応する クラウド型バッテリーマネジメントシステムの開発

Cloud-Based Battery Management System Compatible with Various Batteries by using AI

井本 淳一
Jun-ichi Imoto

南雲 亮佑
Ryosuke Nagumo

福西 孝章
Takaaki Fukunishi

北 篤 佳
Atsuyoshi Kita

阪田 隆 司
Ryuji Sakata

工藤 貴 弘
Takahiro Kudoh

要 旨

地球温暖化対策に伴う電動化の急速な加速により、さまざまな電池に対応できるバッテリーマネジメントが必要となっている。電池開発で培った知見を盛り込んだ独自の機械学習を用いることで、電池状態推定モデルをログデータから自動的に生成することができるクラウド型のバッテリーマネジメントシステムであるUBMC (Universal Battery Management Cloud) を開発した。その性能として、電池残量推定で推定精度1.73%、電池劣化推定で推定精度1.6%と実用十分な結果が得られた。また、高精度な電池状態推定に基づいた価値向上サービスとして、推定精度1.26%の消費電力推定を応用した走行可能範囲推定サービスを例示した。これらの結果から、UBMCがバッテリーマネジメントのプラットフォームとなる期待を述べた。

Abstract

A battery management system compatible with various batteries is needed, because electrification is proceeding apace as a global warming countermeasure. We developed a cloud-based battery management system named UBMC which can build battery state prediction models automatically from log data on the cloud by using the original machine learning method with battery development knowledge. This system achieved sufficient accuracy, 1.73% in SOC estimation and 1.6% in SOH estimation. It also showed that UBMC can serve advanced services based on high accuracy battery state estimation, for example traversable range service with power consumption of 1.26% accuracy. With these results, we hope UBMC will become the platform for battery management.

1. はじめに

地球温暖化対策に伴う再生可能エネルギーの普及や工業製品の電動化を背景に、リチウムイオン二次電池（以下、電池）の需要が高まっている。電池搭載製品では、電池の使い方が製品自体の性能や安全性に大きく影響するため、リスクを回避しながら電池の性能を十分に引き出すバッテリーマネジメント（いわゆる、電池の使いこなし）が重要となる。一方で、電池の残量、劣化、異常といった内部状態は容易には実測できないという特性があり、これら内部状態を把握できていないために、予期せぬ電池切れ（以下、電欠）や交換時期の見過ごしなどのトラブルが生じる可能性がある。特に低価格帯の製品を中心に、製品内部に電池状態推定機能を保有していない製品ではそのリスクが高まる。そのため、電池搭載製品の急速な多様化に対応できるバッテリーマネジメントシステムが必要であり、そのシステムにはさまざまな電池の内部状態を正確に把握し、電池状態推定機能を保有していない製品でも電池の使いこなしを実現できることが求められる。

従来提案されている電池状態推定法として、モデルベースの手法[1]がある。この手法は、電池の電気的特性を電池等価回路モデルで表現し、試験環境での充放電試験により得られたデータを用いて、そのモデルパラメータを同定す

る方法である。モデルは電池パックの品種ごとに用意する必要があり、電池パック内部のセルの数や構成、およびセルの品種が異なる場合は別なモデルとなる。この手法では、モデルごとに数カ月間の開発が必要となることに加え、セルの品種が異なる場合は劣化した時の挙動を把握するための数年規模の試験環境でのデータ収集が必要となる場合もある。また、機械学習ベースの手法[2]も提案されているが、同じように試験環境での充放電試験で得たデータを学習に用いており、高精度化には大量のデータ収集が必要となる。このように、いずれの手法もモデル開発や事前のデータ収集に大きな開発コストが掛かるため、電池搭載製品の急速な多様化への対応が困難である。また、バッテリーマネジメントを提供するサービス[3]も提案され始めているが、製品内部で電池状態推定がなされていることが前提となっている。

以上のように、多様化した幅広い電池搭載製品へ対応するバッテリーマネジメントシステムを実現するためには、電池状態推定モデルを低開発コストで生成する技術、および電池状態推定機能を保有していない製品にも電池の使いこなしを実現する仕組みが必要となる。本稿では、上記の課題に対する取り組みとして、Universal Battery Management Cloud（以下、UBMC）と名付けたAIを活用したクラウド型のバッテリーマネジメントシステムについて報告する。

2. UBMCの概要

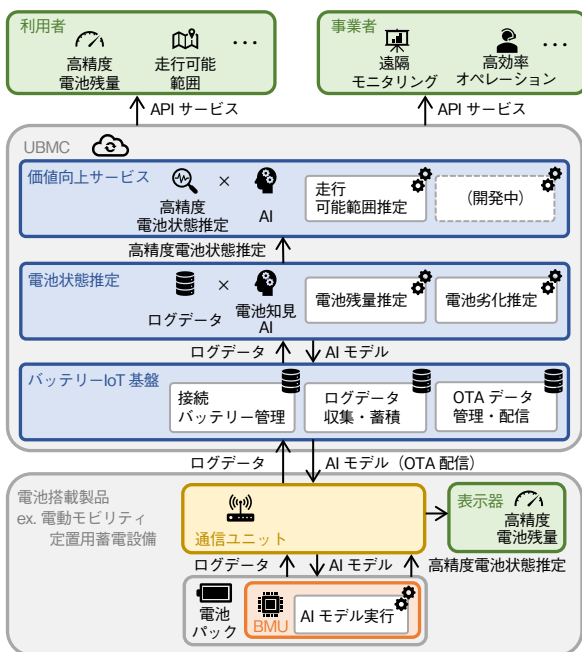
本章では、UBMCの特長および構成について説明する。

2.1 UBMCの特長

- (1) 電池状態推定モデルを低開発コストで生成するために、クラウドに収集した実使用下のログデータから自動的に電池状態推定モデルを生成する。
- (2) 電池状態推定機能を保有していない製品にも電池の使いこなしを実現するために、実使用下のログデータのアップロードのみで適切なバッテリーマネジメントサービスを提供する一気通貫なシステムである。

2.2 UBMCの構成

UBMCの基本的な構成を第1図に示す。UBMCは、バッテリーIoT基盤、電池状態推定、価値向上サービスの3つの機能ブロックから構成される。ここで、電池搭載製品は、電動モビリティや定置用蓄電設備等を想定しており、その電池パックの内部には、基本的な監視や制御を行うBattery Management Unit（以下BMU）が搭載されている構成を想定している。



第1図 UBMCの基本構成
Fig. 1 Basic structure of UBMC

バッテリーIoT基盤は、さまざまな品種や使用環境、内部状態の電池における実使用下のログデータを収集する機能、およびUBMCで生成したAIモデルをエッジデバイスであるBMUにOTA配信（Over The Air）する機能のブロックである。

実際の通信は、通信ユニット等の通信機器を介してエッジデバイスと通信する形態を想定している。

電池状態推定は、バッテリーIoT基盤の機能ブロックで収集した実使用下のログデータに電池知見を盛り込んだ独自の機械学習を適用することで、高精度な電池状態推定モデルを自動的に生成する機能のブロックである。電池残量の推定モデルや電池劣化の推定モデルがその代表例である。それらのAIモデルを自動的に生成するために、学習データに用いる教師ラベルを実使用下のログデータから自動的に作成する。そして、エッジデバイス上での推論処理が必要な場合は、得られたAIモデルをエッジデバイスへOTA配信することができる。その際、BMUのように計算リソースが乏しいエッジデバイスでも推論処理を実行できるように、推定対象に有効な特徴量やアルゴリズムを適切に選定することで、高精度かつ軽量のAIモデルを生成する。また、クラウドで推論処理を行う場合は、AIモデルを使って得られた推論結果をAPI（Application Programming Interface）で公開することで、利用者や事業者へ情報提供することができる。さらに、再学習によるモデルの更新や追加で、劣化した電池や新たな品種の電池へも次々に対応できる。

価値向上サービスは、電池状態推定の機能ブロックで得られる高精度な電池状態推定結果に基づき、利用者や事業者の利用特性に合わせたサービスを提供する機能のブロックである。ここでUBMCでは、その内部に電池状態推定の機能があるため、価値向上サービスの利用には実使用下のログデータのアップロードのみで十分となる。モビリティ利用者向けに地図情報と連携して、電池残量から走行可能な範囲を表示するサービスがその一例である。価値向上サービスは利用シーンによってさまざまな形態を取るため、カスタマイズ性やアップデート性を考慮して、電池状態推定とは別のレイヤとして定義した。また将来的に、外部の開発パートナーにマイクロサービスを開発する領域として開放することも視野に入れている。

3. UBMCの電池状態推定技術

本章では、UBMCの主機能である電池状態推定機能のなかでも、代表的な電池状態である電池残量および電池劣化に関する電池状態推定技術の概要、および検証結果を示す。

3.1 電池残量推定

電池残量（State of Charge、以下SOC）は、特にEV等の電動モビリティにとっては走行距離に直結する重要な情報であり、リアルタイムに取得できることが必要となる。そこで、高精度なSOCをエッジデバイスでリアルタイムに推定することに対応できる機械学習モデルを構築する。

〔1〕 処理概要

実使用下における放電時のログデータからSOCを推定する機械学習モデルを構築する手順について述べる。

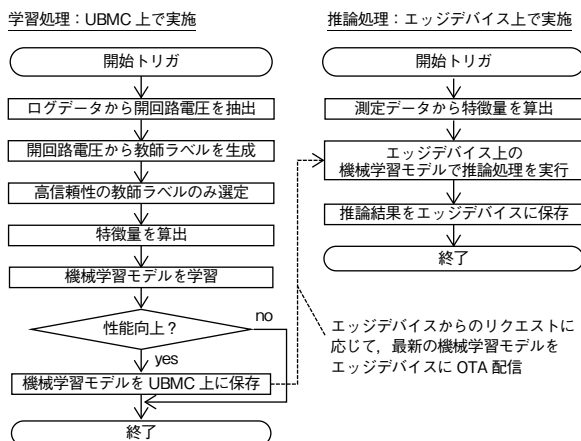
(1) 学習処理

学習処理はUBMCに蓄積されたログデータを用いて、電池パック品種ごとに実施する。SOC推定の機械学習モデルを学習させるうえで問題となるのが、信頼できる教師ラベルが実使用下のログデータには存在しないことである。これを解決するために、ログデータのなかから開回路電圧 (Open Circuit Voltage, 以下OCV) を抽出し、その値を基準にして教師ラベルを付与する技術を開発した。さらに、一定の信頼度を設定することで、その信頼度を超えるデータのみを選別して教師ラベルを付与することとした。

このようにして作成したデータセットに対して、特徴量の算出を行い、機械学習モデルを学習させる。特徴量としては、ログデータに含まれる電圧、電流、温度などの情報を用いる。また、機械学習アルゴリズムとしては、推論処理における演算量が少ない決定木ベースのアルゴリズムのなかでも高精度が得やすいことで知られるXGBoost[4]を用いた。このアルゴリズムの選定により、高精度な推定と軽量のモデルによるエッジデバイス上での推論処理実行を両立することができた。

(2) 推論処理

UBMCで学習した機械学習モデルをエッジデバイスにOTA配信し、エッジデバイス上で推論処理を実行する。エッジデバイスのなかにも特徴量の算出や推論処理のアルゴリズムを実装しておくことで、OTA配信された機械学習モデルを用いて、SOCを逐次的に推定することができる。これにより、利用者は、車両の通信状態やクラウドサービスとの通信タイムラグなどを気にすることなく、リアルタイムに電池残量を把握することができる。



第2図 SOC推定における概略処理フロー


Fig. 2 Process flow for SOC estimation

以上のSOC推定における学習および推論処理の概略処理フローを第2図に示す。

〔2〕 評価結果

EVバイクに搭載された電池パックのログデータを使って、本技術の有用性を検証した。23個体の電池パックに対して、1個体当たり平均13日分の実走行データを収集した。この内の18個体のデータを学習用データとして機械学習モデルの学習処理に使用し、残りの5個体のデータを評価用データとしてモデル性能の評価に使用した。

結果として、評価データ全体に対するSOC推定精度は平均絶対誤差 (Mean Absolute Error, 以下MAE) で1.73%, 最大絶対誤差で10.28%となり、モビリティ用途で必要となる平均絶対誤差5%を上回る高い推定精度を実現できた。評価データにおける時系列のSOC推論結果の一部を第3図に示す。電流値変動が不規則かつ大きい実使用下においても、十分なSOC推定精度を実現していることがわかる。これらの結果から、本技術におけるSOC推定が実用に耐える高い有用性を確認できた。



第3図 電池残量推定の検証結果

Fig. 3 SOC estimation verification results

3.2 電池劣化推定

繰り返し利用可能な二次電池は、使用や保存に伴い利用可能量が減っていく。初期の満充電容量を100%とした時の現在の満充電容量の割合をState of Health (以下、SOH) と呼び、電池劣化の指標として用いる。SOHはSOC0%から100%まで充放電することで実測できるが、実利用シーンでは完全放電となるSOC0%まで使用することは稀 (まれ) であるため、普段の充放電データからSOHを推定する機能が求められる。そこで、実使用下のログデータから高精度なSOHを推定する機械学習モデルを構築する。

〔1〕 処理概要

1回の充電から得られる時系列のログデータからSOHを推定する機械学習モデルを構築する手順について述べる。

(1) 学習処理

学習処理はUBMCに蓄積されたログデータを用いて、電池品種ごとに実施する。学習処理に必要となる信頼性の高い教師ラベルを得るために、深い放電深度（Depth of Discharge, 以下DOD）まで放電された後の充電時のログデータを用いた。理想的にはDOD100%となるSOC0%から100%までの充電時のログデータが望ましいが、一定水準以上の深いDODをもつ充電でも容量確認運転相当とみなし、その時のデータを用いて満充電容量（Full Charge Capacity, 以下FCC）を算出できると判断したためである。実使用下において、深いDODをもつ充電データは稀にしか得られないことが多いが、UBMCは多数の電池のログデータを継続的に収集するシステムであり、蓄積された大量のデータのなかから一定量の深いDODをもつ充電時のログデータを抽出することが可能である。

このようにして作成したデータセットに対して、特徴量の算出を行い、機械学習モデルを学習させる。特徴量としては、充電時のログデータに含まれる電圧、電流、温度の情報に対するSOC帯ごとの差分時系列データを用いる。ここでも学習アルゴリズムはXGBoostを用いた。このアルゴリズムは高精度が期待できることに加えて、入力パラメータの欠損を許容できる特徴があり、浅いDODをもつ充電において差分時系列データが特徴量を定義するすべてのSOC帯に対して用意できない場合でも、高精度なSOHの推論処理が可能となる。

(2) 推論処理

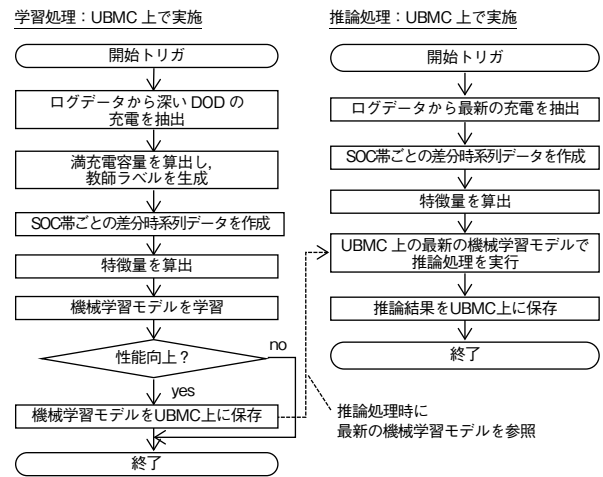
電池劣化を表現するSOHは、短時間での変化量は微小であり、SOCとは異なりリアルタイムな取得は必要ではない。そのため、学習処理で構築した機械学習モデルを用いて、UBMC上で推論処理も行う。そしてAPIを通じて、推定結果を提供することで、利用者は管理する電池の劣化状態を遠隔で把握することができる。

以上のSOH推定における学習および推論処理の概略処理フローを第4図に示す。

[2] 評価結果


EVバイクに搭載された電池パックのログデータを使って、本技術の有用性を検証した。273個体の電池パックに対して約1年間分の充電データを収集した。教師ラベルとなるSOHの計測回数は1460個であった。なお、本検証では定められた期間のなかで一定量の教師ラベルを確実に取得するために、SOC0%まで意図的に放電する作業を定期的に行っている。また、計測したSOHが100%を超えているのは実際の満充電容量が初期の満充電容量として定義した定格容量を上回っているためである。モデル性能の評価は、交差検証で実施した。

結果として、交差検証でのSOH推定精度が二乗平均平方



第4図 SOH推定における概略処理フロー
Fig. 4 Process flow for SOH estimation

根誤差（Root Mean Square Error, 以下RMSE）で1.6%となり、エッジデバイスに組み込まれている従来技術での推定精度4.8%を上回る高い推定精度を実現できた。本技術および従来技術における、各個体に対する真値と推定値の関係性を第5図に示す。その分布形状からも、本技術で得られた推定値が従来技術に対して高い信頼性があることがわかり、その有用性を確認できた。



第5図 電池劣化推定の検証結果
Fig. 5 SOH estimation verification results

3.3 効果

以上のように、実使用下のログデータに対し、電池の特性を理解したうえで、適切に教師ラベルを生成し、かつ推論対象に有効な特徴量やアルゴリズムを選定した独自の機械学習を適用することで、高精度な電池状態推定モデルを自動的に生成することができた。これは、電池状態推定モデルごとに大きな開発コストが掛かる従来技術とは異なり、UBMCがさまざまな電池に対して電池状態推定を提供できることを示している。

4. UBMCの価値向上サービス

UBMCでは高精度な電池状態推定をベースに、利用特性に合わせたサービスを拡充することで、より付加価値の高いバッテリーマネジメント、つまり電池の使いこなしを実現する。本章では、その一例として、電動モビリティ利用者向けの走行可能範囲推定の機能について述べる。

4.1 走行可能範囲推定

電動モビリティ利用者にとって、現在の電池残量で目的地まで到達できるか否かが大きな関心事となる。そこで、UBMCでは走行可能範囲を地図上に表示するための価値向上サービスを追加している。第6図にGoogleマップ(注1)上に、走行可能範囲推定サービスを適用して到達可能性の大小によって道の色を分けることで可視化した例を示している。この例では、到達可能性の大小によって道の色を分けることで可視化している。



第6図 走行可能範囲表示システムの画面例

Fig. 6 Display example of the travelable range estimation system

本機能の実現のためには、地図上に複数の目的候補地を設定したうえで、

- (1) 現在地から各目的候補地までの2地点間に対する地理的特徴量を含む経路情報の生成
 - (2) 経路情報を用いて現在地から各目的候補地に到達するために必要となる電力量の推定
- を高速に実行する必要となる。本節では、(2)の消費電力推定技術の概要および評価結果について述べる。

〔1〕 処理概要

消費電力推定技術では、ある2地点間の移動に関する地理的特徴量やユーザー・車両・電池に関する特徴量、時間特徴量等から、その移動によって消費する電力量を推定する

(注1) GoogleマップおよびGoogle MapsはGoogle LLCの登録商標。

機械学習モデルを構築する。

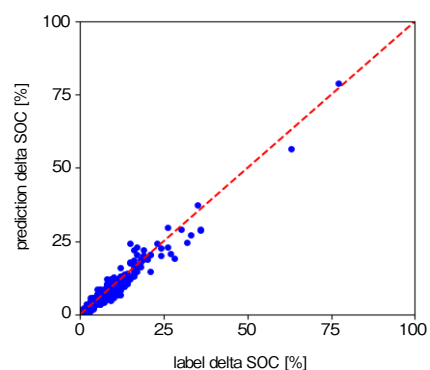
モデルの学習は、UBMCに蓄積された全車両の走行ログデータを用いて行う。まず、走行ログデータを適切な走行区間に分割し、各走行区間の始点から終点への移動に関する特徴量とその走行区間で消費した電力量を算出する。この時の電力量が教師ラベルとなり、今回はSOCの変化量として定義した。ここで、教師ラベルとするSOCが高精度に出力されていることが消費電力推定技術の前提となることから、高精度な電池状態推定技術に基づいた技術となる。次に、XGBoostと同様に高精度が期待できる機械学習アルゴリズムであるLightGBMを用いてモデルを学習し、UBMC上のモデルを更新する。

画面を表示する際、つまり推論処理を実行する際は、最新のモデルを用いて目的地までの消費電力量を推定し、現在の残電力量に照らして走行可能性の判定を行う。推論処理にはリアルタイム性が必要ではあるが、地図情報を用いる必要があることからUBMC上での実行としている。

〔2〕 評価結果

実際の車両の走行ログデータを用いて本技術の性能評価を行った。12台の電気自動車の1年間分の走行ログデータから、9442個の走行区間を抽出し、その内の90%を学習用データ、残りの10%を評価用データとして評価を行った。

結果として、SOC変化量の推定誤差は、RMSEで1.26%、平均絶対誤差率 (Mean Absolute Percentage Error, MAPE) で14.6%となった。第7図に評価用データに対する推定値と真値の関係を示す。このように、SOC変化量の推定値は真値をよく再現しており、走行可能な範囲を地図上に表示する用途において、十分に実用的な予測精度を有していることがわかる。



第7図 消費電力推定の検証結果

Fig. 7 Consumed power estimation verification results

5. まとめ

本稿では、多様化した幅広い電池搭載製品への対応を見

据え、AIを活用してさまざまな電池に対応するクラウド型バッテリーマネジメントシステムであるUBMCについて述べた。UBMCでは、電池開発で培った知見を活（い）かして、クラウドに収集した実使用下のログデータから学習データを生成し、電池状態推定を行うAIモデルを自動的に生成することで、電池状態推定モデルごとに掛かる大きな開発コストを不要とした。また、推定対象に有効な特徴量やアルゴリズムを選定しているため、高精度かつ軽量な電池状態推定モデルの生成を実現した。さらに、ログデータの収集と再学習によるモデルの更新を継続することで、劣化した電池や新たな品種の電池にも次々に対応できる。適用事例として、電動バイクに搭載された電池に対するSOC推定がMAEで1.73%、SOH推定がRMSEで1.6%とどちらも有用性を確認した。さらに、高精度な電池状態推定結果に基づく価値向上サービスの拡充により、さまざまな利用者や事業者の利用特性に合わせたバッテリーマネジメントを実現しており、一例として電動モビリティ向けの走行可能範囲推定のサービスについて示した。これらの活用として、高精度な残量推定や走行可能範囲推定から、移動途中での電欠や余分な継ぎ足し充電を回避し、目的地までの効率の良い移動を実現することが挙げられる。また高精度な劣化推定から、使用期間だけで画一的に電池を交換するのではなく、劣化状態に応じた交換とすることで、劣化の進んでいない電池を不要に交換してしまうことや、急速な劣化により不安全状態に陥った電池の交換遅れを防止することも考えられる。このように、UBMCは多様化した幅広い電池搭載製品に対応できるバッテリーマネジメントシステムであり、電池の使いこなしを実現するプラットフォームである。

現在、国内の電動バイクメーカー様へのサービス導入の実績[5]があり、今後も継続的なアップデートによるサービスの拡充を実施していき、モビリティ事業者やエネルギー事業者を中心に、さまざまな顧客への導入を目指している。

参考文献

- [1] 大矢将輝 他, "パラメータ依存状態空間モデルに基づく蓄電池のSOC推定," システム制御情報学会論文誌, vol.29, no.10, pp. 433-440, 2016.
- [2] Kristen A. Severson et al., "Data-driven prediction of battery cycle life before capacity degradation," Nature Energy vol. 4, pp. 383-391, Mar. 2019.
- [3] 谷澤哲 他, "つながる電池と新しいe-モビリティ," FUJITSU, vol. 65, no. 4, p.26-33, 2014.
- [4] T. Chen et al., "XGBoost: A Scalable Tree Boosting System," KDD '16: Proceedings of the 22nd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining, San Francisco, Aug. 2016.

- [5] パナソニック（株）, "電動モビリティのバッテリー状態を把握し、安心して利用できるクラウド型バッテリーマネジメントサービス「UBMCサービス」を提供開始," <https://news.panasonic.com/jp/press/data/2020/11/jn201125-2/jn201125-2.html>, 参照 Oct. 20, 2021.

執筆者紹介



井本 淳一 Jun-ichi Imoto
テクノロジー本部 デジタル・AI技術センター
Digital & AI Technology Center, Technology Div.




南雲 亮佑 Ryoosuke Nagumo
テクノロジー本部 デジタル・AI技術センター
Digital & AI Technology Center, Technology Div.



福西 孝章 Takaaki Fukunishi
テクノロジー本部 デジタル・AI技術センター
Digital & AI Technology Center, Technology Div.



北 篤佳 Atsuyoshi Kita
テクノロジー本部 デジタル・AI技術センター
Digital & AI Technology Center, Technology Div.



阪田 隆司 Ryuji Sakata
テクノロジー本部 デジタル・AI技術センター
Digital & AI Technology Center, Technology Div.



工藤 貴弘 Takahiro Kudoh
テクノロジー本部 デジタル・AI技術センター
Digital & AI Technology Center, Technology Div.