

# IoTプラットフォームを基盤とした顧客協創による 予知保全ソリューション

Chetan Gupta

Ahmed Farahat

蛭田 智昭

Hiruta Tomoaki

Kosta Ristovski

Umeshwar Dayal

センサーやスマートマシン、計測機器の普及に伴って、機械の稼働中に生成される多種多様なデータが増え続けている。日立の顧客は、そこで収集されたデータからビジネス価値を引き出せるソリューションを求めようになっている。業種をまたがった顧客との対話から、顧客の需要に応える予知保全のソリューションが早急に必要であることが明らかになってきた。

予知保全ソリューションが求められる理由としては、機器の稼働率の向上、予期しない故障に伴うコストの削減、運転の予測性能の向上などが挙げられる。

日立は、幅広いデータアナリティクスのポートフォリオを提供して、さまざまな業種のユースケースに取り組んでいる。本稿では、この分野における日立の取り組みについて概説する。

## 1. はじめに

われわれは現在、農業から製造業、鉱業からエネルギー生産、そしてヘルスケアから輸送に至るまで、いくつもの業界にまたがる大きな変革の最先端にいる。その変革には、経済生産を効率化し、費用対効果と持続可能性を向上させることが期待されている。そして、こうした変革を牽（けん）引しているのが、グローバルな産業システム（OT：制御技術）と、高度なコンピューティング、アナリティクス、低コストのセンシング、およびネットワークを統合する力（IT：情報技術）との融合である。これにより、システムの監視、運用、最適化制御のための新しい形のビッグデータソリューションが成立する。

日立は、広い分野でこうしたソリューションが求められていると考えている。われわれは、機器製造における数十年の経験を、アナリティクスの専門知識と融合して活用し、顧客が抱える重大な課題を解決する独自のソリューションを提供することができる。このビジョンを実現するために創設されたのが、社会イノベーション協創センター（以下、「CSI」と記す）である。CSIは、顧客にとって価値のある新しいソリューションを生み出す方法論を考案してきた（図1参照）。これは、デザインの方法論を用いて顧客と対話し、そのニーズと弱点を理解することから始まる。次の段階では、プロトタイプとなるソリューションと

デモを開発し、さらに顧客サイトでの概念実証（Proof of Concept）に移る。こうしたプロトタイプソリューションを開発するために、各極のCSIとテクノロジーイノベーションセンター（CTI）と連携してプロジェクトを推進している。そして最終段階では、ビジネスユニットと協力して、同じ業種の複数の顧客に対しても、また異なる業種の顧客

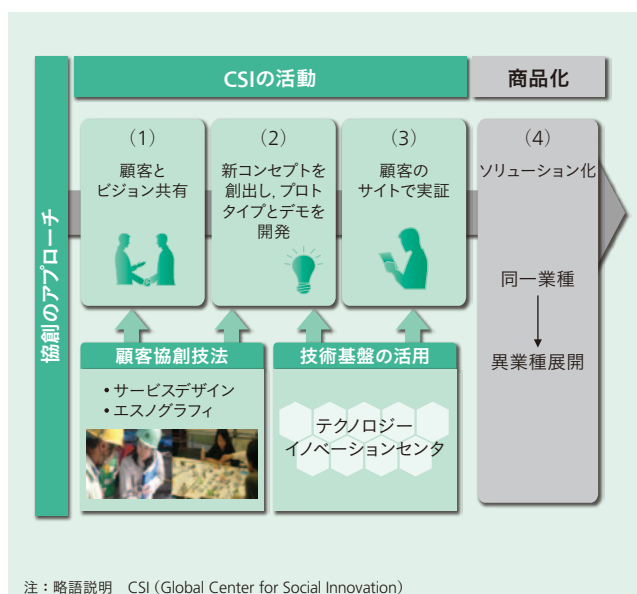


図1 | 予知保全ソリューションのための顧客協創

顧客にとって価値のある新しいソリューションを生み出す顧客協創手順の各段階を示す。

に対してもソリューションを拡大していく。

異なる業種間に共通する1つの応用分野が、予知保全ソリューション、つまり「適切なメンテナンスを適切なタイミングで行う」機能である。これには、機器のパフォーマンスの監視とモデル化、メンテナンスの分析、そして言うまでもなく故障予測が含まれる。予知保全では、ダウンタイムを低減し、予期しない故障に伴うコストを削減できるため、機器の稼働率、機器の性能予測、信頼性が向上する。機器ベンダの場合には、予知保全ソリューションは、新しいサービスとビジネスモデルへの道を開く。

本稿では、日立が顧客協創を通じて開発した予知保全の技術について概要を紹介する。そのうえで、実用的なユースケースも示し、日立のIoTプラットフォームLumadaで利用可能となる予知保全ソリューションと、共通の分析フレームワークについて説明する。

本稿はこれ以降、以下のように構成される。第2章では、予知保全の概要と、日立が顧客に提供しているソリューションについて紹介する。第3章では、予知保全における重要な課題として、故障予測のユースケースを取り上げる。第4章では、再利用可能な予知保全ソリューションの構築方法について説明し、第5章で結論を述べる。

## 2. 予知保全のためのデータアナリティクス

メンテナンスとは、機器を正常で効率的な、費用対効果の高い状態に保つことを目的としたプロセスを言う。メンテナンスのプロセスは、そうした目的を達成するために、機器に対して必要なアクションを実行する。それらのアクションには、機器またはそのコンポーネントの検査、チューニング、修理、オーバーホールが含まれるが、それに限定されるわけではない。

予知保全とは、機器の状態を監視しておき、メンテナンスの適切なタイミングおよびアクションを決定するメンテナンス方式である。予知保全には、事後保全や予防保全など他の方式と比べて多くのメリットがある。予期しない故障の確率が減って機器の稼働率が向上し、メンテナンスコストが必然的に下がるからである。

予知保全の技術には、次のいずれか、または両方が利用される。

### (1) 物理デバイス<sup>1)</sup>

機器の状態診断を支援する。振動モニタリング、潤滑油分析、粒子摩耗分析、サーモグラフィ、および超音波解析などの従来利用されてきたデバイスがこれに該当する。

### (2) ソフトウェア技術

機器や他の物理デバイスによって生成されるセンサーデータとイベントデータを、メンテナンスおよび運転デー

タとともに継続的に監視・分析する。

予知保全に用いられるソフトウェア技術は、さらに以下のように分類できる。

#### (a) ナレッジ主導型システム

対象機器の状態(例えば故障前の状態)についての情報を、機器のメーカーや該当分野の専門家が手動で符号化する。これは、機器の制御ソフトウェアに組み込むソフトウェアベースの予知保全で最も一般的な技術である。ただしこの技術は、想定される機器の状態パターンについて分野専門家が持っている知識、あるいは設計時に利用される物理モデルの精度によって制限を受ける。複雑な機器になると、この手法ではサブコンポーネント間の相互関係を把握できない。そのため、機器の実際の動作は、物理ベースのシミュレーションモデルや、人手であらかじめ生成されたルールからは逸脱することが多い。

#### (b) データ主導型システム

対象機器の状態についての情報を、センサーの履歴データおよびイベントログから取得する。ナレッジ主導型の場合とは異なり、データを分析する際に、設計時または展開時に分野専門家が見逃しやすいた複雑なパターンも捕捉できる可能性がある。

予知保全で用いられるデータアナリティクスは、記述的、予測的、処方的の3つに分類される。本章では以下、その3つのカテゴリで日立が提供している技術の一部を紹介する。

## 2.1 記述的アナリティクス

記述的アナリティクスでは、機器の運転に関する履歴データから、「行動につながる洞察」を引き出す。この洞察を通じて、メンテナンス担当者や経営幹部はメンテナンスプロセスを改善し、機器の運転における非効率を排除できる。予知保全に用いられる記述的アナリティクスの例を、以下に挙げる。

### 2.1.1 性能劣化の検出

この技術は当初、10年近く現場で使われてきた一連の機器の性能劣化を把握したいと要望する顧客のために開発したものである。これには、機器またはそのコンポーネントの性能がゆるやかに低下する場合の検出も含まれる。ゆるやかな性能劣化は、何らかの故障があることの早期警告である可能性がある。あるいは、機器が効率もしくは費用対効果の悪い状態にあり、対処が必要であることを反映しているとも考えられる。性能劣化を検出する日立のソリューションでは、あらかじめ決められた性能指標に基づいて、履歴データから機器の理想的な性能を学習する。性

能指標は、特定分野の研究者と協力して定義され、機器の負荷や季節性の影響を排除するために機械学習を用いて正規化されるのが一般的である。正規化した性能指標を継続的に監視することで、性能の低下を検出することができる。そのため、十分に早期の警告が可能となり、保守員は故障を未然に防ぐ、あるいは効率的で費用対効果の高い状態に機器を戻せることになる。

### 2.1.2 メンテナンス効果の推定

メンテナンス効果推定の技術では、メンテナンスの前後で性能を統計的に分析する<sup>2)</sup>。当初この技術の開発は、機器のメンテナンスを定期的なスケジュールで実施しているが、それが現状で本当に効果的かどうかを知りたいと考えていた顧客との密接な協力で進められた。メンテナンス効果の推定は、個々のメンテナンス、または同種のメンテナンスが、統計的に有意な性能向上につながったかどうかを判断する。この種の分析は、保守員にとって非常に重要である。例えば、保守員は過去のメンテナンスや進行中のメンテナンスに関するフィードバックを受け取ることができ、機器を望ましい状態に保つことに成功した(成功している)かどうかを確かめることができる。また、特定のメンテナンスで、機器のコンポーネントの性能が想定どおりに向上しなかったことを把握できれば、保守員は効果的な対策をすぐに実施できる。しかも、機器の実際の測定値に基づくこのような洞察があれば、メンテナンスオペレーターや経営幹部は、日々のメンテナンス措置を改善し、プロバイダを変えるなど一群の機器に対するメンテナンスプロセスを見直せるようになる。

## 2.2 予測的アナリティクス

これは、履歴データの学習に基づいて、主に故障など将来的なイベントを予測する技術である。故障予測は、予知保全の中で予測的アナリティクスのカテゴリに分類される重要な課題である。日立は、故障予測についてさまざまなユースケースを扱うアルゴリズムを、広範なポートフォリオで用意している。その技術については、第3章で詳述する。

## 2.3 処方的アナリティクス

これは、メンテナンス担当者や経営幹部に対して、運用の目的を満たしながら、故障率も軽減できる推奨事項を提供する技術である。処方的アナリティクスには、以下のようなものがある。

### 2.3.1 動作範囲の推奨

履歴データから、動作目標を達成しつつ故障率を軽減できる動作状態のサブセットを取得する技術である(同様の

アプローチで運用コストを削減することもできるが、これは予知保全の範疇には該当しない)。例えば、日立は相関分析を用いて、大型トラックの動作状態が故障率にどう影響するかを研究している。これは、故障率が通常より高くなってきたため、これまでの生産率を落とすことなく故障率を引き下げたいと考えていた、ある顧客の事例であった。このような相関関係からルールを構築し、故障率を将来的に軽減できるような推奨事項をドライバーに提供する。

### 2.3.2 メンテナンス最適化

分析や人間の判断に基づく洞察、予測、および推奨事項が増えてくると、メンテナンスチームは、どのメンテナンスを採用すべきかを判断したり、特定のメンテナンスの全体的な影響を理解したりするのが困難になることがある。例えば、2つの予測機構から同時に、まったく別々の機器のメンテナンスが直ちに必要であると推奨されても、メンテナンスリソースに限りがあって不可能な場合がある。こうした問題を回避するために、日立は総合的な最適化フレームワークを開発している。これは、さまざまなコスト概算と動作制約も踏まえたうえで、予知保全のアルゴリズムを使って、最大限の動作効率と最小限のメンテナンスコストとなるメンテナンス計画を推奨するフレームワークである。

## 3. 故障予測のユースケース

故障予測は、予知保全において重要な問題である。望ましくない状態やイベントの発生を予防する対策を実施できる十分に早い段階で、その状態やイベントが発生する確率を概算することが目的である。故障予測の技術では、機器の故障前の状態について情報を符号化し、その状態を調べるセンサーデータやイベントデータをリアルタイムで監視する。日立は、故障予測についてさまざまなユースケースに対処する技術のポートフォリオを用意している。イベントベース、センサーベース、物理モデルベースの故障予測である。

### 3.1 イベントベースの故障予測

未加工のセンサーデータを収集することが、コストの関係で現実的でない場合、一般的にはイベントデータしか分析に利用できない。このような場合には、機器のリアルタイムのセンサーデータから、タイムスタンプの記録されたイベントが生成され、運用データベースに転送される。日立が開発した技術では、このようなイベントを時系列として扱う。この時系列に対してデータマイニングを用いれば、イベント間の可能性のある関連性を導き出すことがで

きる<sup>3)</sup>。

イベント間の関連性を見つけるデータマイニングは、当初、マーケットバスケットデータ分析のために開発された。その後、環境モニタリングやバイオインフォマティクス、遠距離通信など各分野の課題に対処できるように新しいアプローチが生み出されている。時系列または非時系列のイベントにおけるマイニング頻度や希少パターンといった問題に対処するアプローチである。日立の技術は、既存のアプローチの1つをアップデートしたものであり、イベントの時系列をマイニングし、あらかじめ指定した期間に有意なイベントの共起がないかどうかを調べる。そのような共起が確認できた場合には、今後の故障を予測するために、イベント間の関連性であるルールを定義する。こうすれば、そのルールを対象のイベントに適用して、一定期間で起こりうる故障の発生を予測できる。つまり、予防保全が可能になる。この技術の位置づけをを図2に示す。

日立は、ある顧客の大型可搬式の鉱山機械で生成されるイベントデータに、この技術を応用した。最も高い信頼度で得られたルールの一部を表1に示す。こうしたルールは、重要な意味を持つことが多い。例えば、車両センサーからCAN (Controlled Area Network) バスデータを得られない場合でも、表1の4行目のルールに基づいてエンジン異常を予測することができた。このルールは、いずれかの

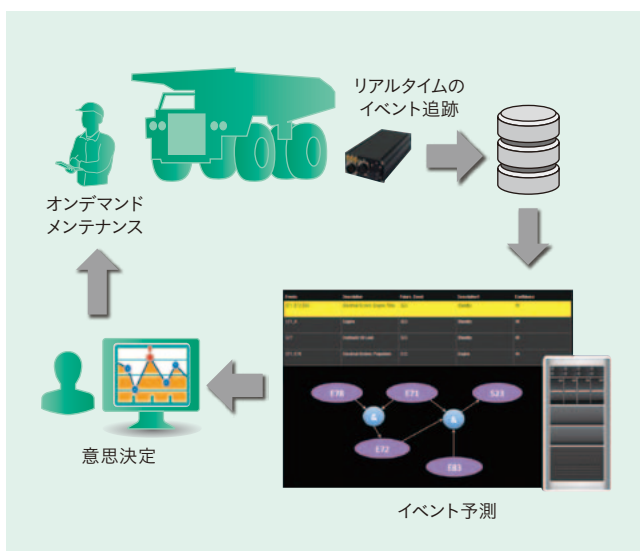


図2 | イベントベースの故障予測システム

イベント間の関連性を見つけるデータマイニングを用いて、故障の予測ルールを導き出す。

表1 | 故障予測のルール

大型可搬装置で得られた故障予測のルールを示す。

イベント	説明	予測	影響	信頼度
E71, E72, E83	電気系統, エンジン, タイヤ	S23	スタンバイ	99%
E71_A	エンジン	S23	スタンバイ	96%
E77	油圧オイル漏れ	S23	スタンバイ	95%
E71, E78	電気系統, 推力	E72	エンジン	64%

機器で電気系統と推力に問題が発生した場合、64%の信頼度で10日以内にエンジン異常が発生することを示しているからである（あらかじめ指定された期間は10日であった）。

大型可搬式の鉱山機械の事例を通して、機器のイベントデータしか利用できないユースケースでも、われわれの故障予測の技術が有用であることが示された。

### 3.2 センサーベースの故障予測

センサーの測定値を利用できる場合、そこには故障前の状態について豊富な情報が反映されている。初めに、われわれは機械学習のアルゴリズムを用いて、センサー測定値の履歴から故障前の状態を学習し、故障予測モデルを生成する。次に、そのモデルをリアルタイムデータに適用して故障を予測する。センサーデータを使った故障予測では、以下の2つのアプローチを紹介する。

#### 3.2.1 異常検出による故障予測

センサー測定値の履歴データから、機器の正常動作のモデルを学習し、機器の運転中にその正常動作からの逸脱を検出する予測方法である。異常検出のアルゴリズムは、センサー測定値の空間上で正常なデータ群を導き出し、次に正常なデータ群と新しい測定値の離れ具合に基づいて、その測定値の異常スコアを計算する。このアルゴリズムは、正常動作に関するセンサー測定値は十分に蓄積されているが、故障履歴が不足しているというユースケースに適している。日立は、例えば発電機のような重機を含めた、さまざまな顧客の故障予測のユースケースで、このアルゴリズムを適用して、成果を上げることができた。

#### 3.2.2 分類による故障予測

分類アルゴリズム<sup>4)</sup>を利用し、故障履歴を用いて複雑な故障前パターンを導き出す予測方法である。このアルゴリズムは、過去の時系列データを正常な期間と故障前の期間に分割し、正常な状態と故障前の状態とを分類する二項分類のモデルを学習する。異常検出による予測とは違い、特定タイプの故障を認識できるが、故障のタイプごとに十分なサンプル数の故障履歴が必要である。日立の顧客環境でも、この技術の提供することで、多くの成功例が確認されている。中でも、冷却システムや、機器ベンダおよび運輸会社が所有する車両など、熱機関を持つ機器を対象とした故障予測のユースケースに、この技術を適用した。機器のセンサー測定値の一部と、この技術で算出した故障の発生確率を図3に示す。

### 3.3 物理モデルベースの故障予測

分類ベースの故障予測では、タイプ別に多数の故障事例




図3 | センサーベースの故障予測

センサー測定値を複数の分類器に当てはめると、それぞれの故障が今後発生する確率が計算される。

が必要である。現場で故障発生頻度が低い場合、われわれは機器の物理モデルを利用し、必要な故障事例をシミュレートする(図4参照)。

物理モデルは、機器の電気系統と機械系統を表す数学的な方程式を用いて定義される。物理モデルを構築する際には、社内の分野専門家と協力するか、パートナー各社とのオープンイノベーションを実行することもある。Xerox社の子会社であるPalo Alto Research Center(パロアルト研究所)と共同で、いくつかのシステムコンポーネントの物理モデルを開発した。また、物理モデルに故障モードと故障度合いを導入した。そのため、われわれの物理モデルではあらかじめ指定した故障モードと故障度合いに応じてデータをシミュレートすることができる。

物理モデルを使用する場合、現場で得られるデータをシ

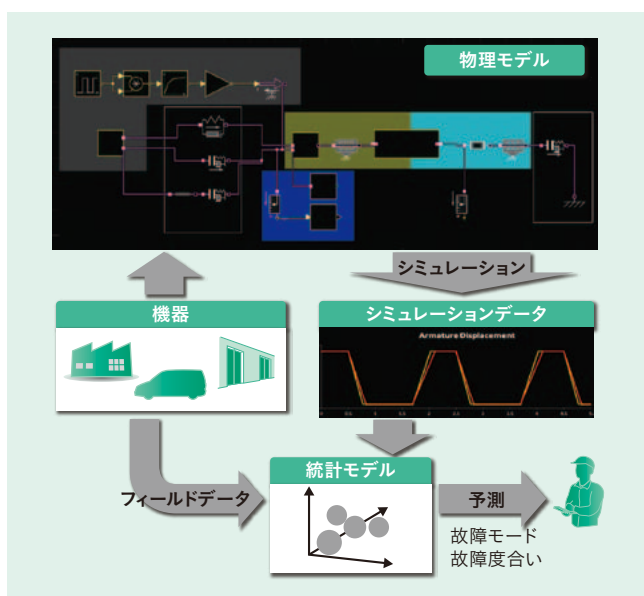


図4 | 物理モデルベースの故障予測

機器の物理モデルは、正常動作と異常動作に関するシミュレーションデータを生成できる。

ミュレーションデータで補完できるため、高い精度で故障予測モデルが得られる。日立は、専門分野の知識を利用して物理モデルとデータアナリティクスを確立し、複数の分野で予知保全アルゴリズムを改善することに成功している。

#### 4. 共通分析フレームワーク上のソリューションとLumada

ここまでに見てきたように、必要とされる予知保全ソリューションは業種によって異なっている。従来は、そうしたニーズの違いに対処するために、課題および分野に特化したソリューションを構築していた。こうしたアプローチと異なり、予知保全フレームワークのために、日立は、共通のフレームワーク<sup>5)</sup>を構築し、日立のIoTソリューションプラットフォームLumada<sup>6)</sup>に統合しようとしている(図5参照)。これにより、再利用可能な予知保全ソリューションの開発が可能になる。日立の予知保全フレームワークは、センサーデータとイベントデータの処理を目的に設計されており、予知保全ソリューションの豊富なコンポーネントライブラリが用意されている。予知保全フレームワークを展開する日立のアプローチには、以下のような長所がある。

(1) 予知保全ソリューションでは、基礎となるアーキテクチャが業種間で共通していることが多い。例えば、センサーデータまたはイベントデータ(あるいはその両方)、メンテナンスデータなどの処理がソリューションには必要である。日立のフレームワークでは、構造化データや非構造化データ、また格納されたデータからストリームデータまで、多岐にわたる種類のデータの管理、処理、および分析が可能である。特に、データ統合、高度な分析と視覚化の機能などが、予知保全のユースケースに合わせて提供される。そのため、新しい予知保全ソリューションを構築する際には時間も労力も費用も削減される。

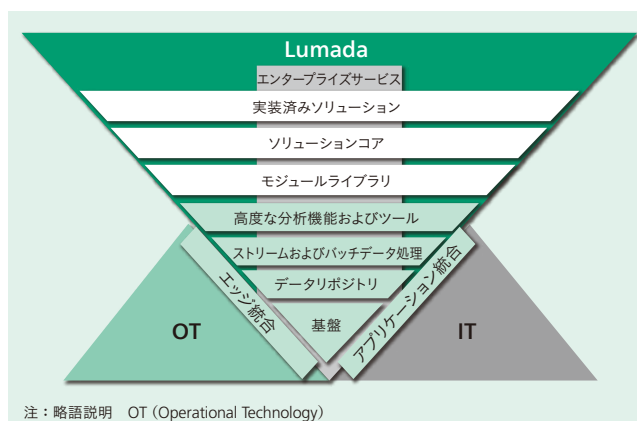


図5 | IoTプラットフォームLumada

予知保全ソリューションの構築のために利用される日立のIoTプラットフォームである。

(2) 再利用可能な分析ソリューションコンポーネントにより、ある分野で得られた知識を他の分野にも利用できる。例えば、冷却装置について開発した性能劣化の検出技術は、KPI (Key Performance Indicator) を変更するだけで自動車にも応用できる。冷却装置のユースケースに応じて開発した性能劣化の検出方法を利用して、自動車業界で性能劣化の検出ソリューションを開発すれば、あらかじめ構築されているソリューションコンポーネントを呼び出すだけで済む。

(3) 産業分野の分析アプリケーションは、ITの専門家によってITの専門家のために設計されていることが多いため、応用性が限られ、採用率も低いことが多い。日立の予知保全フレームワークは、各分野の専門家が使いこなせるように設計されている。そのために、分野専門家が直感的に分析し、独自のダッシュボードを作成することが、ごく簡単なユーザーインターフェースによって可能になっている。

## 5. おわりに

本稿では、密接な顧客協創を通して開発された予知保全のためのデータアナリティクスのポートフォリオを概説した。

日立の技術では、データマイニングと機械学習のアルゴリズムを利用して、機器の履歴について「行動につながる洞察」を引き出し、発生するより前に故障を予測したうえで、その故障発生を未然に防ぐための対策を推奨する。日立のソリューションの基盤になっているのは、Lumadaと、予知保全ソリューションコンポーネントのライブラリを提供する共通フレームワークである。

### 参考文献

- 1) R. Keith Mobley: An Introduction to Predictive Maintenance, Second Edition, Butterworth-Heinemann (2002)
- 2) R. Lyman Ott et al.: An Introduction to Statistical Methods and Data Analysis, Cengage Learning (2010)
- 3) Pang-Ning Tan et al.: Introduction to Data Mining, First Edition, Pearson, pp. 327-390 (2005)
- 4) T. Hastie et al.: The Elements of Statistical Learning: Data Mining, Inference, and Prediction, Springer Series in Statistics (2009)
- 5) C. Gupta et al.: Analytics-Driven Industrial Big Data Applications, Japan Industrial Management Association, Management Systems, Vol. 25, No. 2
- 6) Hitachi Press Release, Hitachi Unveils Lumada Internet of Things Core Platform (May 2016), <https://www.hitachiinsightgroup.com/en-us/pdf/press-release/hitachi-unveils-lumada-internet-of-things-core-platform.pdf>

### 執筆者紹介



**Chetan Gupta, Ph. D.**

Big Data Lab, R&D Division, Hitachi America, Ltd., Global Center for Social Innovation North America 所属  
Big Data Labの主任データサイエンティスト 兼 部門マネージャー



**Ahmed Farahat, Ph. D.**

Big Data Lab, R&D Division, Hitachi America, Ltd., Global Center for Social Innovation North America 所属  
現在、予知保全のための新技術の開発に従事



**蛭田 智昭**

Big Data Lab, R&D Division, Hitachi America, Ltd., Global Center for Social Innovation North America 所属  
現在、予知保全関連の新技術の開発に従事  
日本機械学会 (JSME) 会員



**Kosta Ristovski, Ph. D.**

Big Data Lab, R&D Division, Hitachi America, Ltd., Global Center for Social Innovation North America 所属  
現在、フリート分析および予知保全のための新技術の開発に従事



**Umeshwar Dayal, Ph. D.**

Big Data Lab, R&D Division, Hitachi America, Ltd., Global Center for Social Innovation North America 所属  
CSI北米で、シニアフェローとしてSilicon Valley Research Centerをマネージ