



手軽な機械学習がAPMの可能性を開く

ジョンヘイグ Aspen Technology, Inc.、アセットパフォーマンス
管理担当シニアバイスプレジデント兼ゼネラルマネージャー

はじめに

新しい手法や最先端のテクノロジーがアセットパフォーマンス管理(APM)の機能をかつてないほどに向上させ、その実用的価値を急速に押し上げています。(ここで言うアセットとは主に装置などのハードウェアを指す) クラウドコンピューティングやデータサイエンス、機械学習といったテクノロジーが今、自動化手法とともにAPMソリューションへと直接統合されるようになってきているためです。

この統合の波によって、以前は想像もできなかった拡張性と操作性を備えた高度な分析技術が、オペレーターやエンジニアの手に確実に届けられるようになりました。デジタル変革がもたらす進歩の前では、過去20年にわたるAPMの漸進的進歩が色褪せてしまうほどです。

運用上の負荷がきわめて低い「手軽な」機械学習は、APMの可能性を大きく開く推進力となります。これは、従来の基本原則ベースのソリューションを用いても、コンサルタントエンジニアやデータサイエンティストが「束」になってかかっても、到底成し得なかったことです。機械学習をAPMに大規模に統合することで、エンジニアリングや統計による予測モデルから、実際のアセットの動作パターンの測定へと移行することになります。

今や製造工場のスタッフが、何十年にもわたって蓄積してきた設計や運用データから容易に価値を引き出し、アセットのパフォーマンスをより適切に管理して最適化することが可能になりました。この「手軽な」機械学習手法では、アセットの動作における変化を継続的に取り込み、APMの価値創造をリアルタイムで利用できるようにします。手軽な機械学習は、さまざまな業界で精査やテストが行われ、複数のアセットに拡張することができ、クラウドや並列計算を利用するため、あらゆる業界にとってパフォーマンスと最適化の新時代における導き手となるでしょう。

**手軽な機械学習
は、あらゆる業界に
とってパフォーマンス
と最適化の新時代
における導き手
となるでしょう。**

手軽な機械学習に至るまでのAPMの歩み

新しいAPMのビジョンを実現するための基礎はすでに存在しています。それは、幾人ものエンジニアが数十年にわたっていくつものパフォーマンスモデルを採用してきた実績によるものです。APMを真っ先に導入してきた先駆者たちは、各自のモデルをめぐるテクノロジー上のさまざまな課題や制約に直面してきました。異なるシステムが入り混じった環境では、メンテナンス機能の管理と最適化、リスクの評価と重要度の策定、継続的な状態の監視といった作業が生じてしまいます。

これらのシステムは互いに切り離されていたため、ワークフローが非効率になるだけでなく、接続性や統合性も限られていました。統合性に乏しい初期のコンピューターでは、洞察を得ることがきわめて重要な場合でも、利用できるわずかな関連データがリアルタイムではなくバッチモードで処理されていました。そのため、結果が出るのがきわめて遅く、数日から数週間かかることが一般的でした。新しいアルゴリズムの発展において、計算能力が足かせとなっていました。また、安定した静的モデルは柔軟性に欠け、更新頻度が低いため、新たな動作故障や運用の随時変更に対応できませんでした。

2000年代が到来すると、主要業界が状態ベースの監視に向けてアセットの増強に乗り出すと同時に、計算能力が向上し続けました。システムは切り離されたままでしたが、エンジニアは個別のシステムに含まれるリアルタイムのアセットレベルのデータのようなものに注目し始めました。このような進歩によって新たな洞察が得られるようになった反面、複雑さやデータ品質上の問題も発生しました。コンピューティングプラットフォームは十分な拡張性を備えておらず、膨大なデータの処理にとつてもないコストがかかりました。データへのアクセス性を高めるメカニズムとして限られたレプリケーションが採用されましたが、またしても新たなデータ品質の問題が生じました。つまり、APMソフトウェアは、正確で信頼性の高い診断や明確な提案をはっきりと示すほど進化していなかったということです。



機械ベースのシステムで、計画的保全や使用量および条件ベースの監視といった手法によって信頼性がある程度向上しても、まだアセットの主な故障原因を特定して、それに対応する能力は限られていました。得られる実用的な洞察はきわめて限られており、多くのシステムアラートで誤検知(パフォーマンスの低下や故障イベントに関する不正確な通知)が発生していました。エンジニアはこのような期待外れの結果への対応に追われ、これらのアプローチに対して否定的な印象を抱くようになりました。

わかりやすい例として、独立したパイプラインなどの単一システムが挙げられます。パイプラインシステムに沿っていくつかのアセットに設置された複数のセンサーから、温度や圧力、流量などのさまざまな状態の測定値が定期的に報告されます。1990年代から2000年代の古典的なモデルベースのテクノロジーや統計テクノロジーは、異常検出専用で設計されていました。異常検出ではエラーが頻繁に発生し、常に専門の担当者が結果を解釈して、アラートの正誤を見分ける必要があります。

パイプラインでは、エンジニアのもとに何百件ものリークに関する誤検知アラートが押し寄せました。社内スタッフは、それらのアラートを無視するわけにはいかず、かといってその妥当性を正確に評価する手立てもありませんでした。こうして運用上の整合性に支障が生じ、システムの信頼性が損なわれました。

現在でも、アラートによってアセットの整合性を確保できると謳う多くのシステムが、正常ではないという事の検出しか行えない設計になっています。相変わらずコンサルタントスタッフが間に入り、故障の回避やリスクの軽減に向けて取るべき一連の行動を解釈しなければなりません。万が一パイプラインのリークが検出されると膨大なコストがかかることから、過剰な保全を行い、多額のコンサルティング料を支払っているのが現状です。手軽な機械学習は、そうした状況を一変させるテクノロジーです。非常に精度の高い正確な故障パターン認識を導入して、故障が発生する数か月前に通知されるようにすることができます。これにより、アプリケーションの価値を実現するための多くのリソースや専門知識が不要になります。

手軽な機械学習は、そうした状況を一変させるテクノロジーです。非常に精度の高い正確な故障パターン認識を導入して、故障が発生する数か月前に通知されるようにすることができます。



2000年代は基礎づくり

2000年代の後半には、いくつかの革新的な並列化テクノロジーが最先端のAPM手法へと融合されました。クラス最高のシステムでは、通常の動作と故障が発生した場合の動作の正確なパターンを検出する機能を組み込めるようになり、劣化を示す重要な指標を自動的に分離することが可能になりました。特筆すべきは、スケーラブルなクラウドコンピューティングを実現した2006年のAmazon Web Servicesのデビューでしょう。構造化・非構造化データベースと運用データプールの最新技術が企業レベルでテストされ、強化されたのがこの時期です。

時を同じくして、スマートセンサーの性能やサイズ、信頼性、価格に劇的な変化が見られるようになります。加えて、機械学習の計算・分析能力が大幅に向上し、「Deep Belief Network」すなわち「ディープラーニング」が登場しました。この画期的発明の先駆者は、トロント大学のジェフリー・ヒントン氏です。同氏は現在、Googleと緊密に連携しています。

その結果、機能が飛躍的に進歩し、モデリング手法や統計的手法の制約となっていた従来の分析技術のパフォーマンスを超える機械学習が誕生しました。今や機械学習は世界中のあらゆるIT分野における主要な分析手法となり、クレジットカードの不正検知や、Facebookによる顔認識、Amazon、Apple、Googleによる音声認識、自動運転車の操縦、医療診断などに幅広く利用されるようになっていきます。

2007年のiPhoneのデビューに先導されたスマートフォンの台頭はこの時期です。これにより、コンピューターリテラシーが大幅に向上し、複雑なアプリ機能が一般に普及しました。

市場をリードする多くの企業が従来の予防保全でできることはすべてやったと感じており、これからは予知保全が目指すべき領域であると言えます。

2007年から2010年の期間は、iPadのデビューで締め括られました。プロセス産業の従業員は、産業用モノのインターネット(IIoT)を用いた実験から、職場でのスマートデバイスや消費者向けアプリケーションの使用を求める段階へと移行しました。産業用のソフトウェアやテクノロジーでは、手軽に操作できるアプリケーションや表示を取り入れたユーザーインターフェースによってサービスや製品が更新されるようになり、ベンダー各社は、生産性の向上に高度なスキルや経験を必要としない直感的なソフトウェアの提供に乗り出しました。

その頃、多くのオーナーオペレータ企業が出資した業界横断型の取り組みが、異種混合システムと業務プロセスの中間作業——とりわけ運用と保守システム——をつなぐオープンスタンダードの開発へとつながりました。

このような取り組みによって、問題に対処し、これまで実現できなかったソリューションを実現するために、データを組み合わせて包括的に利用できるようになりました。こうした手法とテクノロジーアプローチの自動化の融合が、APMのパフォーマンスと価値を大きく飛躍させるための基礎となりました。

この時期、アセット、特に機械的アセットに対する保全業務に役立つ新たな手法が検討されるようになりました。故障に対する事後対応から、予定表や使用量、状態に基づく計画的保全イベントを経て、信頼性中心保全(RCM)の手法へと移行するすべての過程で、徐々に改善が加えられました。しかし、コスト、複雑さ、時間、スタッフ配置のスキルセットといった要件が、展開上の制約となりました。

現在、予期しないアセットの故障が生じる問題を保全だけでは解決できないという認識が高まっています。ARC Advisory Group¹によると、機械的な故障の82%が不規則な故障パターンを示し、現行の保全作業では監視していないプロセス起因の状態が原因となっています。

市場をリードする多くの企業が従来の予防保全でできることはすべてやったと感じており、これからは予知保全が目指すべき領域であると言えます。



手軽な機械学習の新たな時代に突入

最先端の信頼性管理手法の展開先候補として真っ先に挙げられるのが、各種製造業におけるデータ集約型の複雑な環境でしょう。機械学習を適切な自動化とともに一貫して展開すると、俊敏性と柔軟性が高まり、プロセスセンサーだけでなく機械的イベントやプロセスイベントからも現在の状態や過去の状態、予想される状態を取り込めるようになります。システムは自動化され、コンサルタントの負荷の高い従来型のアプローチは過去のものとなりつつあります。代わりに、実際のデータの状態を学習し、それに適応する俊敏性の高い柔軟なモデルが登場して、実際のアセットの動作に関する微妙な違いもすべて取り込まれるようになっていきます。

データ容量と計算能力に優れているため、社内スタッフが個々のプロセスや機械的アセットの管理を積極的かつ正確に行えるようになりました。今やこの管理機能は、プラント全体、システム全体、あるいは複数のロケーションにまたがって、さまざまなアセットの組み合わせに適用することができます。

APMの機能の中心的役割が、プロセス産業をはじめとするさまざまな分野の製造にとって重要な時期に差し掛かっています。多くの組織が非常に大きな経済的プレッシャーにさらされ、当社の顧客との最近の会話や、業界全体の予測を考え合わせると、運用の対前年比の追加節減効果は、過去の利益をすでに得ていることから、1%未満になるとみられます。しかし、現在のごくわずかな営業利益から、プロセス産業のエグゼクティブは、特に運用上の問題を原因とする計画外のダウンタイムの回避や装置の損傷の予防において、APMに投資利益率の向上を期待せざるを得ない状況です。もっとも、手軽な機械学習ベースのAPMなら、いつでもその期待に応えることができます。

プロセス産業では、あらゆる組織が複雑なシステム、状態の変動、無数のアセットに取り組んでいます。市場ニーズ、緊急性、スタッフの数、スキルセットが多岐にわたることから、程度の差こそあれ、プレッシャーを受けるポイントが数多く存在します。ここでその実例を見てみましょう。

- 某精油業者では、頻発するアセットの故障に手を焼いています。同社のコンプレッサーは適切に設置され、RCMが定期的な検査や整備とともに実施されていますが、予期しない故障がどうしても発生してしまいます。
- 中間貯蔵タンクを複数抱える某化学メーカーでは、供給ポンプの間欠故障が発生することがあります。故障が発生すると、ダウンタイムが増大し、生産性が低下します。
- 老朽化した複雑な配電網は、高度な分析アプローチを必要としています。アセットの平均寿命しかわからないため、推測で保全スケジュールを立てています。将来の需要モデルを作成することができず、輪番停電が発生する可能性があります。結果的に、保全にコストをかけすぎ、配電網の性能に格差が生じてしまいます。

そこへ、手軽な機械学習ベースのAPMを利用すれば、これらすべての問題に対処できます。



手軽な機械学習ベースのAPMに関するベストプラクティス

俊敏性、柔軟性、適応性、拡張性は、プロセス産業で信頼性を確保する上で欠かせない要素です。そして、手軽な機械学習ベースのAPMだけがこれらの能力を備えています。以下に機械学習に関する5つのベストプラクティスを紹介します。これらのベストプラクティスによって、業界を問わず、最先端の信頼性管理を、1つのロケーションから全国規模のシステムまで、あらゆるレベルの任意のアセットに適用できます。

手軽な機械学習ベースのAPMに関する5つのベストプラクティス

1. データの収集と準備
2. 状態ベースの監視
3. 作業管理履歴
4. 予測分析と処方的分析
5. プール分析とフリート分析

データの収集と準備

過去20年にわたり、センサーから収集されたプラントデータのさまざまなソースに対して大規模なデータ分析を試みるたびに、収集や適時性、検証、クレンジング、正規化、同期、構造に関する深刻な問題に突き当たってきました。「ガベージイン、ガベージアウト」(間違ったデータを入力すれば、間違った出力しか出てこない)と言われる状態です。

このようなデータの準備には、データマイニングとデータ分析の実行と繰り返しにかかる時間の50~80%を費やすことも珍しくありません。しかし、このプロセスは、エンドユーザーがその後の分析結果を信頼できるようにするために、適切かつ正確なデータを確保する上で不可欠なものです。最先端のAPM手法によってデータ準備プロセスの大部分が自動化されたことで、ユーザーによる準備を最小限に抑えながら、信頼を保証し、これまで発見されなかったチャンスを引き出せるようになりました。

状態ベースの監視

データの信頼を確保したら、状態ベースの監視(CBM)を適用できるようになります。プラントの状態は、アセットの機械的性能、材料の品質の変化、気象条件、製造のタイムラインや需要の変化によって絶えず変わります。このような強制的な環境では、静的モデルは機能しません。また、機械的設備の動作に対するCBMで明らかにできるのは、劣化や故障¹を引き起こす真の問題のごく一部にすぎません¹。

市場をリードする組織は、故障の大半の原因となる顕著なプロセス起因の状態を無視することの多い従来のCBMでは十分に対処できなくなっていることに気付いています。一方、最先端のAPM手法では、故障につながる可能性のある機械的な状態や、上流および下流プロセスの状態をすべて包括的に監視できます。

作業管理履歴

作業履歴は、故障の予防や修復に対する過去の解決策の記録となります。問題の特定、コーディング、問題解決の標準的アプローチでは、アセットのライフサイクルにおける正確な故障ポイントの重要な基準が得られます。ビッグデータソリューションに含まれている可能性のあるOEMデータからは、対象のプラントプロセス内の構成やエンジニアリングに特有のプロセス上の問題や異常値について洞察が得られることが期待できます。

先見性のある組織は、このようなデータの重要性とともに、それが最終的にアセットの故障につながる生産の劣化をきわめて正確に予測する上でいかに役立つかを理解しています。

予測分析と処方的分析

クリーンデータとCBMによって、現場での予測分析が可能になります。予測分析とは、過去の動作を解釈し、その分析に基づいて将来の結果を予測するプロセスです。それに対して、エンジニアリングモデルや統計モデルを用いてセンサーの将来の測定値を予測し、実際の測定値との差異を解釈する手法は、多くのエラーや誤検知を伴います。一流企業では、プロセスの設備や機器の通常の動作と故障が発生した場合の動作の各パターンに対して、インラインのリアルタイム分析が使用されています。

予測分析を正しく行くと、アセットのライフサイクルと信頼性を正確に特定して、損傷を伴う後期のアラームよりもかなり早い段階で劣化の根本原因に取り組むことができます。また、多変量の時間的なパターン分析から得られる洞察によって、正確に故障までの時間を導き出せるようになります。これにより、意思決定の時間を確保して、損傷や保全をなくすことや、少なくとも、修理期間を短縮して影響を軽減するための準備時間を確保することが可能になるでしょう。

クラス最高のAPMでは、実証された根本原因分析(RCA)に基づく処方的助言が提供され、損傷の原因となるプロセスの状態を事前に回避するためのアプローチに関する情報や、アセットの整備に必要な正確な保全に関する助言が示されます。

その結果、予測分析や処方的分析の機能によって、アセットのライフサイクルの信頼性を確保できるとともに、生産を最大化するためのタイミングや方法に関する意思決定を促進しながらも、アセットや生産上のリスクを事前に回避できるようになります。このようなリアルタイムの分析から保全スケジュールを作成してアセットを最適化することで、将来の生産またはアセットの問題に関する推測作業が不要になります。最高責任者レベルのエグゼクティブは、プラントやサイトのパフォーマンスに関する全体像が得られるため、取締役会レベルでより大胆なリスク分析やパフォーマンス予測が行えるようになるでしょう。

最高責任者レベルのエグゼクティブは、プラントやサイトのパフォーマンスに関する全体像が得られるため、取締役会レベルでより大胆なリスク分析やパフォーマンス予測が行えるようになるでしょう。



プール分析とフリート分析

分析の次のレベルでは、プールやフリートに含まれる特定の資産で発見されたパターンを共有し、すべての設備に対して共通の安全保護や停止保護を採用することができます。採用した企業では、特定のユニットから、特定の拠点、複数の拠点、さらには全社へとソリューションをすばやく拡張することが可能になります。すべてのローカルシステムの情報をさまざまなサイトから単一のより大規模なモデルへとロールアップすることで、資産のパフォーマンスをサイトやプラント間で比較して、共通の基準を策定し、改善可能な領域を明らかにすることができます。

まとめ

製造の世界が変化した今、従来の保全作業を改善すれば、資産の劣化を招くあらゆる問題を認識できるようになります。組織がいち早く根本原因を特定するための戦略を取り入れることで、計画外のダウンタイムを防ぐための適切な意思決定により多くの時間をかけることが可能になります。

プロセス産業のどの組織でも、ニーズや複雑さに関わらず、手軽な機械学習ベースのAPMを今すぐ導入できます。そうすれば、資産の突発的な故障をなくし、全体的な信頼性を高めて、正味の生産量を増加させ、収益性を向上させることができます。

引用文献

¹ARC Advisory Groupによるウェビナー「Improve Reliability of Process Assets with Prescriptive Analytics: Get Results Today」、2017年6月14日

アスペンテックは、資産のパフォーマンスを最適化するソフトウェアを提供するリーディング企業です。当社の製品は、装置の設計、運用、保守のライフサイクルを最適化することがきわめて重要となる、複雑な業界環境において成功を収めています。アスペンテックは、数十年にわたって培ったプロセスモデリングの専門知識と、ビッグデータに基づく機械学習を、独自の方法で組み合わせています。当社の専用ソフトウェアプラットフォームは、資産のライフサイクル全体で高い利益を提供することで、知識労働を自動化し、持続可能な競争上の優位性を築きます。これにより、さまざまな資本集約型業界の企業が、稼働時間を最大化させ、パフォーマンスの限界を押し上げ、より高速かつ安全に、長期にわたり、より環境に配慮した方法で資産を運用できるようになります。詳しくは、www.aspentech.com もしくは www.aspentech.com/japan をご覧ください。

株式会社アスペンテックジャパン

〒102-0083 東京都千代田区麹町4-8 麹町クリスタルシティ10F

電話：03-3262-1710 ファックス：03-3262-1765 電子メール：atj_marketing@aspentech.com

ホームページ：www.aspentech.com/japan

