

Manutenção preditiva para a indústria de elevadores e escadas rolantes

Serviços inteligentes habilitados por *Industrial Analytics*

Rami Aro¹; Carlos Paiz Gatica²

¹ Global Segment Manager Elevadores e Escadas Rolantes; ² Product Manager Industrial Analytics Solutions

Weidmüller – Sistemas de Interface, S.A.

Palavras como o Elevador Inteligente, *Big Data*, Manutenção Preditiva, entre outras, estão atualmente a inspirar muitos fabricantes de elevadores e escadas rolantes. Com base na manutenção preditiva, o tempo de atividade útil da máquina é projetado para acrescentar valor aos novos sistemas no futuro. No entanto, cada vez mais empresas estão a perceber que a expansão dos serviços baseados em dados (*data-based services*) lhes proporciona uma vantagem comercial real e que esses modelos de negócios preparados para o futuro estão projetados para alavancar a lealdade do cliente a longo prazo. Os métodos usados pela *Industrial Analytics* ajudam a conseguir isso mesmo. As técnicas de *machine learning* e de Inteligência Artificial permitem que os comportamentos da máquina de um elevador ou escada rolante sejam mais bem compreendidos pelo fabricante, revelando estruturas e padrões e fornecendo novas informações sobre as relações de dados. Mas o caminho a percorrer necessita de ser um processo bem organizado. A Weidmüller mostra como descrever o caso de uso e estabelecer uma prova de conceito, enquanto a equipa do projeto percorre as etapas tradicionais de

recolha de dados, integração, preparação, análise, implementação e, finalmente, avalia o benefício económico.

1. INTRODUÇÃO

Vantagens das metodologias de monitorização baseadas num modelo

Os desenvolvimentos tecnológicos dos sistemas de automação em direção à digitalização trazem diversas vantagens e oportunidades como flexibilidade, produção económica de lotes pequenos e otimização dos processos de produção. Além disso, também há grandes desafios para aumentar a fiabilidade e disponibilidade do equipamento, especialmente para empresas de elevadores e escadas rolantes. Outro desafio é o desenvolvimento de estratégias de manutenção mais eficientes, reduzindo custos.

Atualmente os sistemas de monitorização baseados em regras estão bem estabelecidos entre os sistemas dos elevadores, principalmente devido à simplicidade de tal abordagem, onde os limites para sinais individuais (por exemplo, valores de sensor) são configurados por especialistas em aplicações. Se, por exemplo, um motor necessita de ser monitorizado, são definidos os valores limite para indicadores de falha específicos (por exemplo, temperatura, consumo de corrente). Se algum dos sinais monitorizados ultrapassar os limites definidos, um alarme pode ser gerado. Para aplicações simples, as abordagens baseadas em regras são as mais adequadas. No entanto, se para a aplicação as transições dinâmicas de muitos sinais são relevantes para a deteção de falhas, essa tarefa torna-se muito complexa para uma abordagem baseada em regras. Além disso, mudanças no comportamento




Figura 1. Monitorização baseada em regras versus abordagem baseada em modelos.

"Com base na manutenção preditiva, o tempo de atividade útil da máquina é projetado para acrescentar valor aos novos sistemas no futuro."

do sinal que ocorrem entre os limites definidos pelos sistemas de monitorização baseados em regras não são detetáveis, como mostra a Figura 1.

Uma abordagem baseada num modelo pode ser utilizada para melhorar o desempenho de um sistema de monitorização. Um modelo pode representar várias dimensões simultaneamente para que os estados da máquina sejam bem identificáveis. O desenvolvimento de um modelo adequado pode ser muito exigente e requer recursos humanos altamente qualificados. No entanto, usando métodos de *Industrial Analytics* (por exemplo algoritmos de *machine learning*) e dados de processo para derivar um modelo de máquina, a complexidade da implementação de uma função de monitorização pode ser significativamente reduzida [1]. Além disso, a qualidade da monitorização é melhorada à medida que falhas mais complexas, que não são identificáveis com um sistema baseado em regras, podem ser detetadas.

2. FLUXO DE TRABALHO DE INDUSTRIAL ANALYTICS

Da aquisição de dados à visualização

As funções de *Industrial Analytics* são tipicamente compostas por diferentes tarefas, como mostrado na Figura 2. A figura mostra o fluxo de trabalho típico de um aplicativo de *Industrial Analytics*, onde os dados dos diferentes dispositivos são consolidados numa única fonte de dados (armazenamento de dados). O próximo passo é pré-processar os dados como preparação para o processo de aprendizagem (pré-processamento). Nesta etapa os recursos relevantes são extraídos dos sinais de dados brutos, envolvendo a combinação de métodos estatísticos com conhecimento de domínio para selecionar recursos significativos.

O passo seguinte é a seleção, formação e ajuste de algoritmos de *machine learning* para derivar um modelo a partir dos recursos selecionados (aprendizagem de modelo). A combinação de conhecimento analítico e conhecimento de domínio é novamente fundamental para desenvolver um modelo eficiente. Uma vez desenvolvido, o modelo pode ser utilizado em tempo de execução para monitorizar a máquina ou processo (execução do modelo). Para ser útil, os resul-




Figura 2. Fluxo de trabalho típico de um aplicativo de *Industrial Analytics*.

tados precisam de ser visualizados corretamente (visualização). O tipo de visualização deve ser selecionado de acordo com o papel da pessoa que deve usar essa informação, por exemplo o proprietário do edifício, o gestor de instalações ou manutenção, entre outros. A integração de uma função de *Industrial Analytics* num sistema de automação pode ser feita em diferentes níveis, como por exemplo na máquina ou através de uma plataforma na *cloud*. Essas possibilidades são exploradas na próxima secção.

3. TOPOLOGIA PARA A REALIZAÇÃO DE ANÁLISES INDUSTRIAIS

Do sensor à nuvem

A realização das operações básicas da função de análise (armazenamento de dados, pré-processamento, aprendizagem de modelo, pontuação de modelo, e visualização) pode ser feito em diferentes níveis: por exemplo, para coletar dados no nível do componente (condução, carro, portas) e ao nível do campo, por exemplo utilizando um *kit* de sensor e coletando sinais com um sistema E/S remoto. Como as fontes de dados podem ser heterogéneas, existe o requisito de transformar os dados num formato unificado para posterior processamento de análises. Dependendo da aplicação e dos pré-requisitos da aplicação do utilizador, os

dados podem ser armazenados localmente, utilizando o controlador principal ou um *gateway* IoT, ou na nuvem usando serviços de armazenamento adequados na *cloud*, conforme mostrado na Figura 3. O processamento de análise pode ser executado em vários dispositivos ou plataformas ou utilizando *software* como um serviço em plataformas de nuvem. Embora os componentes de automação sejam usados principalmente para o controlo do processo, podem qualificar-se para implementar a funcionalidade de processamento analítico se sobrar uma quantidade adequada de recursos.

Além dos recursos de *hardware* fornecidos, os requisitos de processamento e memória variam de acordo com a tarefa a ser executada. Em especial, derivar um modelo de máquina requer geralmente recursos significativamente maiores do que a execução desse modelo. Existem várias opções de arquitetura para armazenar e processar dados, e a implementação selecionada está sujeita a restrições como por exemplo a arquitetura fornecida, as necessidades de processamento, as taxas de dados e a complexidade do armazenamento. Há uma necessidade de flexibilidade na realização de funções analíticas para abordar as diversas aplicações do setor. Para aplicações em elevadores, os conjuntos de dados são gerados principal-




Figura 3. Possível topologia para coletar dados ao nível do componente e do campo.

mente a partir do controlador em tempo real. Os algoritmos aplicados necessitam de mostrar baixa latência e os conjuntos de dados são tipicamente de pequeno volume e altamente correlacionados entre si. Portanto, uma implementação de funções de *Industrial Analytics* usando dispositivos periféricos (por exemplo, *gateway IoT*) pode trazer muitas vantagens, como tempos de reação curtos e tráfego de rede decrescente.

4. FASES TÍPICAS DE UM PROJETO DE ANÁLISE

Da definição do alvo à implantação

O caminho a percorrer para um projeto de análise deve ser um fluxo de trabalho bem organizado, normalmente de cinco fases, como mostra a Figura 4. Inicialmente está a análise de problemas e a definição de destino. Por exemplo: Quais as falhas específicas que devem ser previsíveis? Durante a fase de exploração de dados, a qualidade dos dados gerados será verificada se as falhas definidas puderem ser detetadas ou se for necessária mais qualida-

de de dados. Durante a prova de conceito, a prova técnica e económica de viabilidade será verificada (análise *offline*). Na fase piloto um protótipo funcional será executado num aplicativo piloto (análise *online*). Finalmente, na última fase, as soluções de análise à prova de piloto serão desenvolvidas e implementadas.

4.1 Análise offline

A aplicação da análise de dados nos dados da máquina começa geralmente com a exploração *offline*. Os dados de amostra de algumas máquinas para um período de tempo representativo selecionado são recuperados e, em seguida, analisados *offline* pelos cientistas de dados. Eles exploram os dados aplicando vários métodos de análise de dados para descobrir quais os métodos que fornecem os melhores *insights* acionáveis. As empresas que oferecem esses serviços diferenciam-se pela capacidade de executar análises *offline* de forma eficiente. Nós, por exemplo, construímos ao longo do tempo uma extensa caixa de ferramentas de ciência de dados e *machine learning* que permite avaliar

dados de amostra num curto espaço de tempo.

4.2 Análise online para manutenção preditiva

Para fins de manutenção preditiva, os dados da máquina necessitam de ser monitorizados continuamente. A partir dos dados adquiridos o estado da máquina é avaliado, eventos anormais e indicadores de falha são detetados e utilizados para identificar a manutenção necessária. Em seguida, as recomendações para atividades de manutenção são fornecidas ao proprietário do edifício ou aos gestores de instalações ou manutenção. Dependendo da natureza das condições físicas que levam a falhas na máquina, pode ser necessário processar dados em tempo quase real com latência inferior a 1 segundo por um lado, ou por outro lado num teste diário ou semanal. Os sistemas de análise *online* devem ser flexíveis para lidar com essa variedade de requisitos de tempo.

Atualmente, consideramos três categorias diferentes de análise que geram informações para sistemas de monitorização de máquinas e manutenção preditiva: cálculos diretos, reconhecimento de estado e atividade da máquina e deteção de anomalias. Cálculos diretos coletam os dados do sensor de uma máquina como *input* e calculam, por exemplo, o desgaste de uma peça da máquina.

Algoritmos de reconhecimento do estado da máquina como *input* consomem leituras do sensor da máquina ou dados do processo para identificar o estado da máquina num determinado ponto no tempo. Usamos tecnologias de *machine learning* para classificar estados e atividades de máquinas com base em modelos aprendidos numa fase da formação anterior [2]. Os estados e atividades da máquina obtidos são úteis para a manutenção preditiva quando mais processamento e raciocínio são realizados.

A deteção de anomalias [3] é outra técnica muito útil para encontrar indicadores de falha e avaliar a necessidade de manutenção. Quando em operação normal, os sinais do sensor estão geralmente dentro de certas faixas de valores ou exibem padrões normais específicos. Obviamente estamos interessados em captar o desvio do comportamento normal. Uma única anomalia




Figura 4.

detetada pode ser indicativa de uma falha e usada para acionar uma ação. Muitas vezes uma única anomalia pode não ser suficiente. Apenas um número crescente de anomalias ao longo do tempo fornecerá indicação de que a máquina não está a funcionar de maneira ideal ou a desenvolver uma condição que necessita de ser resolvida pelo pessoal técnico. Além disso, há muitas razões pelas quais anomalias podem ser detetadas em dados de sensores de máquinas, e muitas delas podem não estar relacionadas com nenhum problema, mas causadas por outros fatores de influência. Por exemplo, a interação do operador ou a alteração das configurações dos parâmetros pode ter um impacto nas medições do sensor. Um recurso importante de uma solução de manutenção preditiva é entender o contexto das medições e avaliar quais as anomalias relevantes para prever as necessidades de manutenção.

5. CONCLUSÃO

Neste documento delineamos o fluxo de trabalho e a topologia das funções de *Industrial Analytics* e descrevemos as cinco fases de um projeto analítico típico. A abordagem *offline* e *online* para realizar a manutenção preditiva foi discutida, mostrando a principal vantagem de combinar a ciência de dados com o *know-how* específico do domínio.

Os dados de máquina gerados a partir de elevadores e escadas rolantes, combinados com dados da empresa de manutenção, são transformados em *insights* poderosos quando as funções de *Industrial Analytics* são aplicadas. Estes dados podem transformar-se em resultados acionáveis como manutenção preditiva, por exemplo identificar, analisar e resolver, de forma preditiva, possíveis problemas de serviço antes que eles ocorram. Isso resulta numa redução ou eliminação do tempo de inatividade.

A Weidmüller pode estabelecer parcerias na realização conjunta de soluções de *Industrial Analytics*, passo a passo, desde a ideia até serviços escalonáveis e inteligentes, e no desenvolvimento de modelos de negócios inovadores baseados em dados. São oferecidas soluções analíticas personalizadas que proporcionam o melhor desempenho possível para as necessidades do cliente. Agimos independentemente da plataforma e podemos realizar implantações locais, na nuvem ou híbridas, independentemente de plataformas de nuvem específicas. As nossas soluções de análise funcionam independentemente do fornecedor, do sistema de automação ou controlo subjacente.

6. REFERÊNCIAS BIBLIOGRÁFICAS

- [1] Alexander Maier, Markus Köster, Carlos Paiz Gatica, und Oliver Niggemann. "Automated Generation of Timing Models in Distributed Production Plants". *IEEE International Conference on Industrial Technology (ICIT 2013)*, Cidade do Cabo, África do Sul, 2013.
- [2] T. Warren Liao. "Clustering of time series data—a survey", *Pattern Recognition, Volume 38, Issue 11* (novembro 2005), páginas 1857-1874.
- [3] Varun Chandola, Arindam Banerjee, and Vipin Kumar. "Anomaly detection: A survey." *ACM Computing Surveys. Volume 41, Issue 3, Article 15* (julho 2009), 58 páginas. ▲