



SIEMENS
Ingenuity for life

Inteligência Operacional XHQ e MindSphere

Análise Avançada

XHQ

Por vinte anos, o Software para Inteligência Operacional XHQ ajudou indústrias em transformação digital. Agora, o XHQ se integra ao MindSphere Predictive Learning para impulsionar um novo nível de inteligência operacional, com aprendizado de máquina e outras análises avançadas. As aplicações MindSphere são enriquecidas com operações complexas, contextualizadas, e dados de negócios disponíveis por meio do XHQ. Este documento ilustra como o XHQ pode trabalhar com o MindSphere Predictive Learning para solucionar problemas comuns.

Conteúdo

1. Apresentação	4
2. O Sistema	5
2.1 XHQ	5
2.2 MindSphere	5
2.3 Analytics	5
3. Integridade do Ativo Fixo	7
3.1 Apresentação	7
3.2 Objetivo	7
3.3 Ideia	7
3.4 Desenvolvendo o Sistema	8
3.5 Usando o Sistema	9
4. Integridade do Equipamento Rotativo	11
4.1 Apresentação	11
4.2 Objetivo	11
4.3 Ideia	11
4.4 Desenvolvendo o Sistema	11
4.5 Usando o Sistema	12
5. Custos de Manutenção	14
5.1 Apresentação	14
5.2 Objetivo	14
5.3 Ideia	14
5.4 Desenvolvendo o Sistema	14
5.5 Usando o Sistema	14
6. Dados não estruturados	15
6.1 Apresentação	15
6.2 Objetivo	15
6.3 Ideia	15
6.4 Desenvolvendo o Sistema	15
6.5 Usando o Sistema	16

1. Apresentação

As indústrias de processos estão passando por uma transformação digital e a análise é uma parte essencial dessa transformação. A disciplina de análise avançada usa ferramentas matemáticas sofisticadas para gerar modelos que podem ser usados para fazer previsões e recomendações. Esses modelos podem ser incorporados a um gêmeo digital (um modelo virtual de um processo ou instalação) para permitir novas e aprimoradas maneiras de operar. O Analytics faz previsões a partir dos dados.

Um sistema de análise bem-sucedido exige quatro elementos. O primeiro elemento é o processamento de dados. Os sistemas de automação sempre produziram grandes quantidades de dados, mas muitas vezes tem sido difícil usá-los para análise. É importante disponibilizar uma grande variedade de dados para treinar e executar análises. O segundo elemento é o desenvolvimento de modelos especializados - o gêmeo digital - de instalações reais que considerem o volume de dados disponíveis e os aspectos específicos da operação. Todas as plantas de processo lidam com a corrosão, mas todas as plantas têm suas diferenças nos hábitos de projeto, construção, idade, operação e manutenção; portanto, os modelos podem precisar ser adaptados a cada instalação. O terceiro elemento é fazer previsões regulares automaticamente. O quarto elemento é apresentar previsões e recomendações de uma maneira que faça sentido para os usuários, e os leve a tomar as ações adequadas.

O XHQ é um software de Inteligência Operacional para as indústrias de processos, reunindo dados de manufatura, operações e equipamentos em um sistema coeso para a

geração de relatórios, análises e visualizações em contexto. O MindSphere Predictive Learning é um sistema de software para análises avançadas, com ferramentas para desenvolver e executar algoritmos, como redes neurais, máquinas de vetores de suporte e florestas aleatórias.

Este documento descreve como a análise avançada pode ser implementada com o XHQ e o MindSphere Predictive Learning. Ele descreve uma abordagem geral e descreve quatro casos para análises avançadas. (Observe que a Siemens geralmente espera adaptar análises como essas a problemas específicos, pois cada cliente tem dados, tipos de ativos e necessidades diferentes).

Integridade do Ativo Fixo. Examinar embarcações, torres, tubulações e outros ativos fixos; identificar ativos de risco, especialmente riscos de corrosão; e recomendar alterações operacionais e de inspeção para prolongar a vida útil do ativo.

Integridade do Equipamento Rotativo. Identificar problemas com bombas e oportunidades para melhorias no processo operacional e de manutenção.

Custos de Manutenção. Comparar gastos e resultados, com destaque em áreas em que a manutenção poderia ser reduzida ou aumentada.

Dados não estruturados. Examinar os comentários do operador e outros dados não estruturados e facilitar a busca por ativos, produtos e outros elementos, independentemente da ortografia.

2. O Sistema

2.1 XHQ

O XHQ é um software de inteligência operacional para indústrias de processos, reunindo dados de manufatura, operações e equipamentos em um sistema coeso para a geração de relatórios, análises e visualizações em contexto. Com o software XHQ, uma fábrica ou empresa de processos pode criar um rico conjunto de painéis e monitores que combinam informações de várias fontes, o que ajuda a equipe a entender rapidamente o verdadeiro estado dos negócios, processos e ativos; solucionar problemas; e gerenciar condições comuns.

A maioria das pessoas interage com o XHQ por meio de páginas personalizadas da web, com foco no atendimento das necessidades locais. As páginas da Web são criadas a partir de widgets que incluem esquemas, figuras, tabelas, gráficos, tendências e GIS.

O XHQ se conecta a qualquer fonte de dados: bancos de dados, registros, manutenção, ERP, qualidade, cadeia de suprimentos e muitos outros - organiza e contextualiza os dados em um modelo de informação coeso, e visualiza os dados. As exibições são orientadas pelo modelo de informações XHQ, que organiza e contextualiza os dados conforme os negócios são organizados - por função, instalação, linha de produção.

2.2 MindSphere

O MindSphere é o sistema operacional de IoT aberto e baseado em nuvem da Siemens, que conecta produtos, fábricas, sistemas e máquinas, permitindo análises avançadas a partir dos dados gravados por meio de Internet das Coisas (IoT).

O MindSphere possui muitos componentes e recursos. O trabalho descrito neste documento utiliza o MindSphere Predictive Learning, que é um serviço de análise preditiva em nuvem usado para desenvolver e aplicar modelos preditivos como soluções de análise. O MindSphere Predictive Learning possui várias partes, incluindo Data Lake, Analytics Workbench, ambiente de runtime e serviços da web. 2.3 Analytics

O Analytics é a descoberta, interpretação e comunicação de padrões significativos nos dados. A análise do MindSphere utiliza o

aprendizado de máquina, que “é uma técnica de ciência de dados que permite que os computadores usem os dados existentes para prever comportamentos, resultados e tendências futuras. Usando o aprendizado de máquina, os computadores aprendem sem a necessidade de uma programação explícita. ... A análise preditiva usa fórmulas matemáticas chamadas algoritmos, que analisam dados históricos ou atuais para identificar padrões ou tendências, a fim de prever eventos futuros.”¹ Normalmente, um especialista usa grandes conjuntos de dados para desenvolver ou **treinar** algoritmos, por exemplo, usando uma grande coleção de dados históricos sobre as vedações de uma bomba, para criar métodos para prever falhas nas vedações. Uma vez desenvolvidos, os algoritmos podem ser executados com novos dados para fazer previsões.

De forma geral, as análises têm um ciclo de vida. Normalmente, há uma fase de **investigação**, em que um cientista de dados, especialista no assunto ou usuário avançado, usa ferramentas para investigar dados em busca de insights ou uma solução para um problema. Por exemplo, um especialista pode analisar falhas de vedação de uma bomba para procurar causas-raiz ou formas de reduzir falhas. A análise pode ser seguida por uma fase de **desenvolvimento** em que um especialista desenvolve ferramentas para uso de outras pessoas, como algoritmos de aprendizado de máquina que preveem a probabilidade de falha. Após o desenvolvimento da ferramentas, elas devem ser **aplicadas** em campo, por exemplo, na configuração de um algoritmo que prevê falhas na vedação de uma bomba, para prever a probabilidade de falha das centenas de bombas reais em uso. Finalmente, os algoritmos precisam ser **executados** para fazer previsões.

Esses nomes - **investigação, desenvolvimento, aplicação e execução** - serão usados neste documento para se referir a essas atividades distintas.

A figura mostra esses estágios operando sequencialmente, e mostra as funções típicas do XHQ e do MindSphere Predictive Learning nessas atividades. Existem muitos outros fluxos e alternativas possíveis. Por exemplo, o XHQ pode se integrar a outros mecanismos de análise além do MindSphere.

¹ Introdução ao Machine Learning em nuvem do Azure. Microsoft Azure. 12 de julho de 2017. Recuperado em 18 de outubro de 2017 em <https://docs.microsoft.com/en-us/azure/machine-learning/studio/what-is-machine-learning>

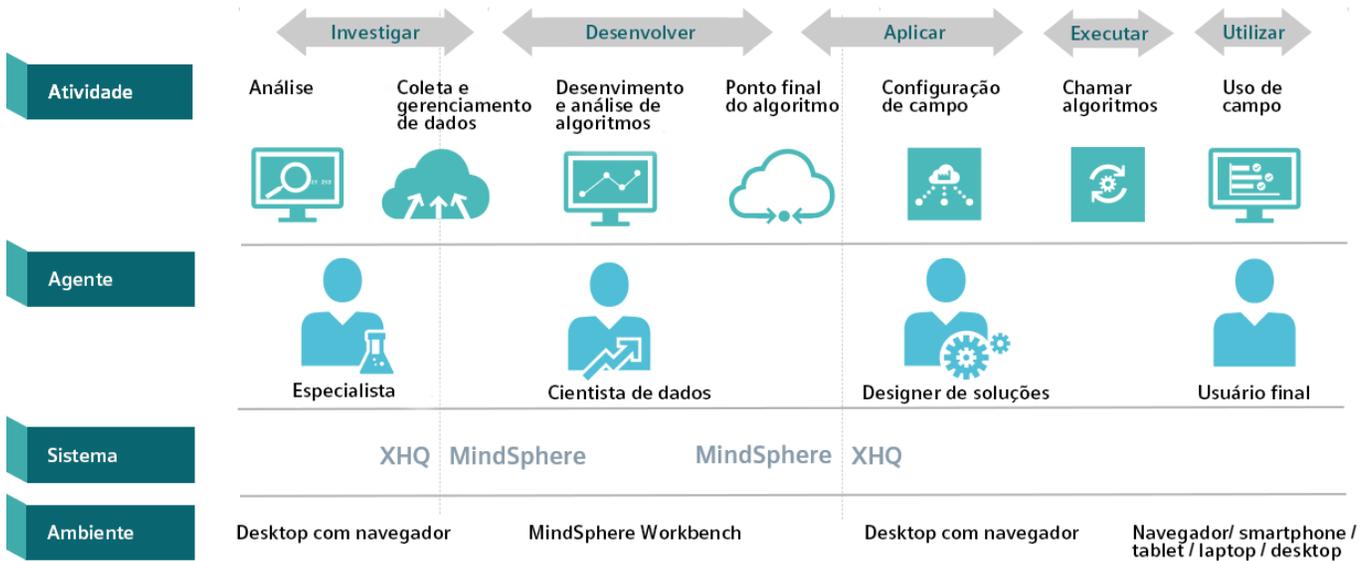


Figura 1. Ciclo de vida do Analytics

Investigação

Geralmente, o primeiro passo é a **investigação** de um problema por um especialista (ou cientista de dados). Essa fase começa quando um usuário decide trabalhar em uma área problemática e termina quando um ou mais conjuntos de dados foram disponibilizados para um Cientista de Dados. As atividades nesta etapa incluem:

- Selecionar dados
- Investigação preliminar dos dados
- Upload de Dados para o Data Lake do MindSphere

O trabalho inicial para selecionar e fazer upload de dados é realizado no XHQ, pois o XHQ tem acesso a todos os dados. A investigação preliminar dos dados - gráficos, filtragem, procura de tendências etc. - pode ser realizada no XHQ ou no MindSphere Predictive Learning, ou em ambos.

Desenvolvimento

O segundo passo é o **desenvolvimento** ou aprimoramento de um algoritmo por um cientista de dados. Essa fase começa com conjuntos de dados que foram fornecidos por um ou mais especialistas e termina com algoritmos *publicados* e disponíveis para uso. Neste documento, os algoritmos são publicados a um "ponto final do algoritmo".

A fase acontece inteiramente no sistema MindSphere Predictive Learning.

Investigação e desenvolvimento são atividades offline que são realizadas ocasionalmente, quando há um novo problema a ser resolvido, ou uma solução antiga precisa ser atualizada.

Inscrição

A terceira etapa é que um XHQ Solution Designer **aplique** e integre os algoritmos às soluções XHQ. Essa fase começa com algoritmos publicados e termina quando os algoritmos são usados na solução XHQ. Essa fase pode envolver a aplicação de um algoritmo para cada membro de uma classe, como a aplicação de uma previsão para cada bomba.

Esta etapa também é uma atividade offline, que ocorre quando a solução ou os ativos XHQ são alterados.

Execução

O quarto e último passo é o uso da produção dos algoritmos, para **executar**, para que os algoritmos possam realizar as previsões. O XHQ está configurado para fornecer dados de entrada ao mecanismo do algoritmo, chamar o mecanismo e disponibilizar os resultados na solução XHQ para uso geral. Os usuários finais veem as novas informações - previsões do mecanismo de análise - incorporadas nas visualizações comuns do XHQ.

Essa fase envolve o XHQ e o ambiente de análise. O XHQ reúne os dados de entrada, os envia para o data lake do MindSphere, e chama os algoritmos no MindSphere. O MindSphere processa os dados, executa os algoritmos e produz as previsões. Por fim, o XHQ busca e exibe os resultados.

3. Integridade do Ativo Fixo

O Analytics pode trazer melhorias ao estudo de ativos fixos como embarcações, torres, tubulações e outros ativos fixos; identificar ativos de risco, especialmente riscos de corrosão; e recomendar alterações operacionais e de inspeção para prolongar a vida útil do ativo.

3.1 Apresentação

A integridade mecânica é importante para prevenir ou minimizar as consequências de vazamentos catastróficos de substâncias tóxicas, reativas,

produtos químicos inflamáveis ou explosivos. Manter a integridade mecânica requer atenção a todos os aspectos do ciclo de vida do equipamento, garantindo que o equipamento seja projetado, instalado, operado e mantido de forma correta. As consequências de falhas na integridade mecânica podem variar de uma perda catastrófica de contenção, a custos excessivos e disponibilidade reduzida.

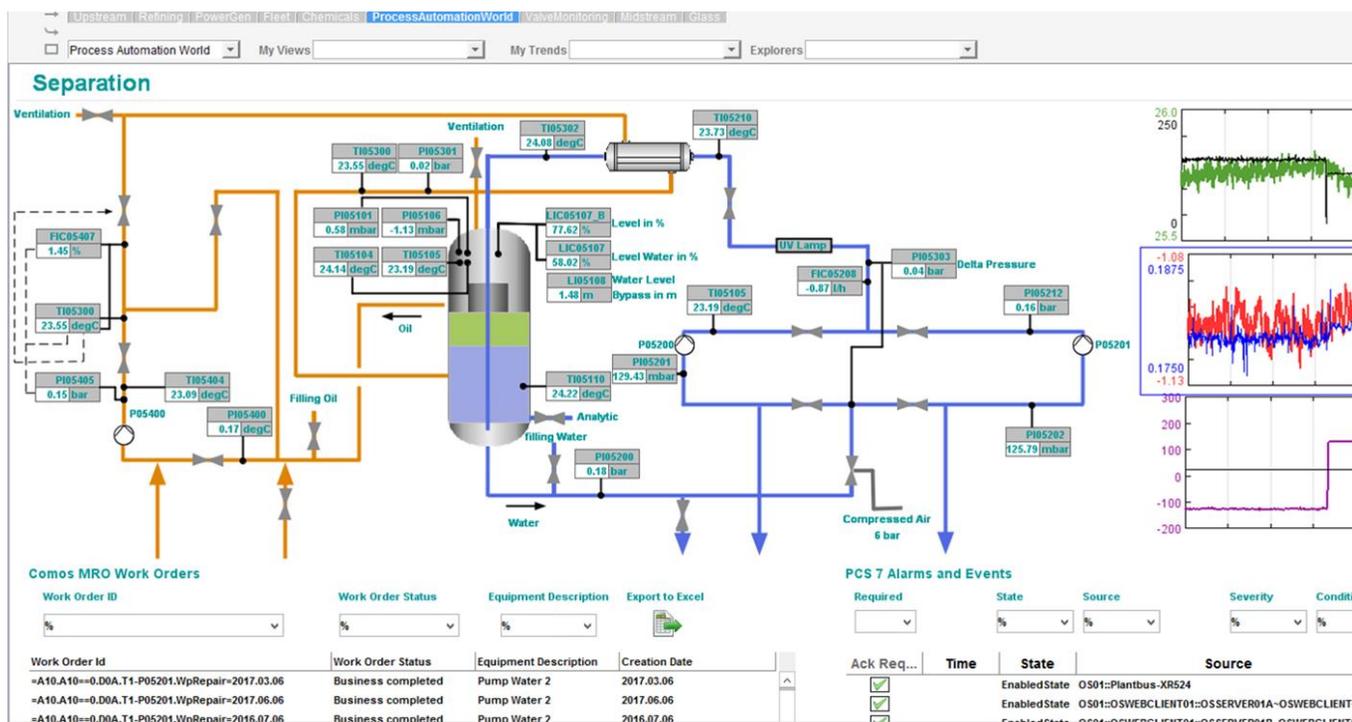


Figura 1. Caso de uso de Integridade do Ativo Fixo

3.2 Objetivo

O objetivo do estudo de Integridade de Ativo Fixo é examinar dados operacionais e informações de ativos usando análises avançadas, avaliar a integridade de ativos e recomendar manutenção e alterações de processo. Um programa bem-sucedido resultaria em um entendimento aprimorado da integridade do ativo, um entendimento aprimorado do que contribui para falhas mecânicas e algoritmos que preveem a integridade do ativo, e fazem recomendações para operações, inspeção e manutenção.

3.3 Ideia

Um engenheiro de confiabilidade tem uma variedade de informações disponíveis: circuitos de corrosão; dados de processo, projeto e mecânicos; leituras de espessura de parede e taxas de corrosão; histórico e custos de manutenção; possivelmente o envelope operacional e uma análise de confiabilidade.



Qual é o risco de corrosão em caso de aumento recente do teor de enxofre?

Essa bobina deve ser substituída agora, ou pode aguardar a próxima inspeção?

A taxa de corrosão observada neste tubo é típica e esperada?

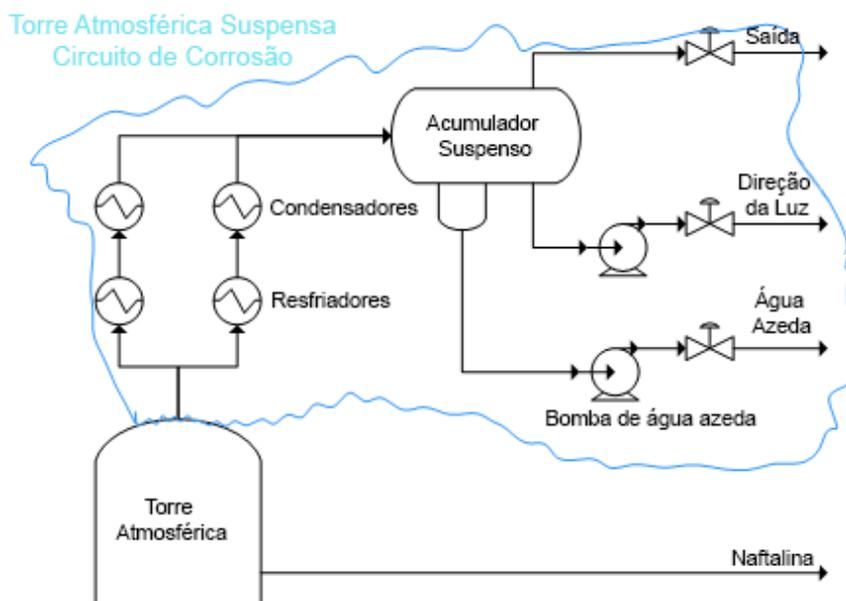
Sem análises, um engenheiro de confiabilidade procurará exceções, como altas taxas de corrosão ou altos custos de manutenção não planejados. Muitas dessas exceções são indicadores de atraso que são sinalizados somente após a corrosão. Um engenheiro de confiabilidade também pode examinar áreas onde existem altos custos planejados de manutenção e sem problemas, para ver se talvez os gastos com manutenção possam ser reduzidos.

O Analytics e o gêmeo digital oferecem uma maneira de fazer previsões sobre ativos. Com a análise, o sistema pode aproveitar todas as informações operacionais para fazer previsões sobre as taxas de corrosão em toda a instalação. Essas previsões podem ser usadas para atualizar planos de manutenção, fazer mais manutenção em áreas de alto risco e menos manutenção em áreas de baixo risco. Além disso, se as

corresponderem às observações, isso pode indicar que o processo mudou e pode ser necessário atualizar planos e perfis de risco.

3.4 Desenvolvendo o Sistema

Organizamos a análise por circuitos de corrosão em uma instalação operacional, e consideramos vários tipos de dados. Os circuitos de corrosão são tipicamente definidos como um grupo de equipamentos que trabalham juntos, são suscetíveis aos mesmos danos, com taxas de corrosão semelhantes. Por exemplo, uma sobrecarga de unidade de destilação bruta inclui hidrocarbonetos leves e água azeda sendo processada através de uma série de trocadores de calor, recipientes e equipamentos relacionados, e as condições são tais que o grupo de equipamentos pode ser tratado em conjunto para fins de avaliação de riscos e mecanismos, devidos à corrosão.



previsões estiverem incorretas e as previsões não

Figura 2. Circuito de corrosão típico para uma sobrecarga de unidade de destilação bruta

Os cientistas de dados usam o MindSphere Predictive Learning para desenvolver algoritmos que fazem previsões sobre a integridade dos ativos, especificamente para a corrosão de elementos como colunas, reatores e trocadores de calor. Esses algoritmos preveem a integridade do ativo, incluindo:

- Tempo provável até a falha
- Probabilidade de o ativo falhar em um determinado período, como nos próximos 30 dias
- Causa mais provável da falha e razões da falha
- Recomendações de manutenção

Esses algoritmos são desenvolvidos - treinados - usando vários anos de dados históricos, incluindo:

Referência de ativos - estes são principalmente dados constantes ou descritivos.

- Condições físicas e mecânicas, como idade do ativo, metalurgia, espessura da parede, tolerâncias
- Projetar condições operacionais
- Mecanismos potenciais de dano e modos de falha, conforme identificados nos documentos de controle de corrosão

Condição do ativo - estes são principalmente dados transacionais.

- Histórico de manutenção, incluindo quaisquer mecanismos de danos relatados
- Termografia infravermelha (fotos IR) que mostra pontos quentes

Dados operacionais - geralmente são dados de séries temporais ou podem ser convertidos para o formato de séries temporais.

- Status do equipamento e histórico operacional
- Taxas de corrosão, espessura da parede e dados de inspeção semelhantes

- Condições do processo, como taxas de fluxo, temperaturas, pressões, conteúdo de enxofre, pH e outras propriedades do fluido, geralmente de um historiador do processo e do LIMS
- Condições ambientais, como temperatura e umidade do ambiente
- Histórico de violações ao IOWs (Integrity Operating Windows).

O XHQ está configurado para mostrar circuitos de corrosão e informações sobre cada circuito, como dados operacionais importantes, histórico de manutenção, envelope de operação e avaliação de risco. Até agora, esse é o padrão de recursos XHQ. As visualizações XHQ são estendidas para mostrar também os resultados das análises, incluindo a exibição de previsões e indicadores de integridade dos ativos, o tempo provável até a falha ou a probabilidade de falha, modos de falha e recomendações de manutenção.

3.5 Usando o Sistema

Os principais usuários são engenheiros de confiabilidade, especialistas em equipamentos e engenheiros de processos.

Todos os dias, o XHQ executa os algoritmos de previsão de corrosão no MindSphere Predictive Learning para cada circuito de corrosão. Para fazer isso, o XHQ reúne a entrada necessária, envia a entrada como arquivos para o data lake na nuvem usada pelo MindSphere, executa o algoritmo, aguarda a conclusão da tarefa, baixa os arquivos de saída para o servidor XHQ e lê os resultados. Todo esse processo é na verdade um conector XHQ, e o processo de execução de algoritmos é invisível para os usuários.

O algoritmo retornará um índice de integridade do ativo - um número - para cada ativo com corrosão, e talvez até mais detalhes. Um índice de integridade com valores ruins acionará alertas e avisos. Por exemplo, suponha que o índice de integridade de sobrecarga da unidade bruta seja pior que o limite. Nesse caso, o sistema gera uma mensagem dizendo que "o circuito aéreo da unidade bruta está em risco de altas taxas de corrosão devido ao alto teor de enxofre no óleo bruto".

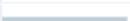
		<i>Integridade</i>		<i>Informações de Suporte</i>				
		HEALTH (%)	REL(%)	MAINT(%)	IOW 1	IOW 2	RISK	BKLG WO
EI & C	Analyzers	 95%	94	100	0.0	0.0	3	0
	Control Loops	 94%	94	95	0.0	0.0	1	1
	Electrical	 99%	100	96	0.0	0.0	2	0
	Instrumentation	 93%	93	94	0.0	0.0	1	3
	Valves	 94%	97	99	0.0	0.0	3	6
Fixed Equipment	Columns	 96%	96	98	0.0	0.0	3	3
	Corrosion Circuits	 89%	92	98	0.0	0.0	4	10
	Piping	 95%	94	91	0.0	0.0	2	12
	Tanks	 92%	93	95	0.0	0.0	3	3
Heaters	Vessels	 98%	95	97	0.0	0.0	1	3
	Boilers	 96%	96	96	0.0	0.0	1	0
	Heaters	 96%	94	92	0.0	0.0	2	0
	Reactors	 100%	100	99	0.0	0.0	1	0

Figura 3. Amostra de tela XHQ destacando problemas com circuitos de corrosão

As pessoas usam essas informações para avaliar a integridade geral das unidades, circuitos de corrosão e ativos. Eles podem atualizar os planos de manutenção e inspeção, por exemplo, solicitando mais leituras de espessura de corrosão. Nos casos em que as análises preveem alto risco para ativos críticos, os engenheiros podem fazer alterações na operação, adicionar mais sensores no campo ou alterar o design do equipamento.

O resultado final são ativos mais confiáveis e melhores previsões de quando a manutenção é necessária, o que reduzirá os custos de manutenção não planejados e melhorará a confiabilidade da unidade.

4. Integridade do Equipamento Rotativo

O Analytics pode melhorar o estudo da integridade dos equipamentos rotativos, identificando problemas com bombas e oportunidades para melhorias no processo operacional e de manutenção.

4.1 Apresentação

As bombas movem fluidos e são equipamentos críticos em qualquer planta de processo. Uma grande refinaria ou fábrica de produtos químicos pode ter centenas, talvez milhares de bombas, incluindo centrífugas, deslocamento positivo, fluxo axial e outros tipos. Os compressores são outro tipo importante de equipamento rotativo e são usados para aumentar a pressão (reduzir o volume) de um gás e bombeá-lo ao mesmo tempo.

Bombas e compressores requerem inspeção e manutenção regulares. Pouca inspeção e manutenção podem resultar em tempo de inatividade não planejado e custos de reparo não planejados, e fazer muita inspeção e manutenção tem um custo sem benefícios.

4.2 Objetivo

O objetivo do estudo de Equipamento Rotativo é examinar dados operacionais e informações de ativos usando análises avançadas, avaliar a integridade de ativos e recomendar manutenção e alterações de processo. Um programa bem-sucedido resultaria em uma melhor compreensão da integridade do equipamento rotativo, algoritmos que prevêm falhas no equipamento, bem como integridade do equipamento e algoritmos que fazem recomendações para operações e manutenção.

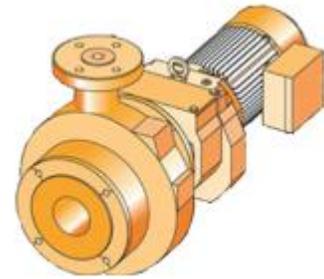
4.3 Ideia

Um especialista em equipamentos rotativos tem uma variedade de informações disponíveis: dados de processo, projeto, mecânica, máquinas e manutenção. Há muitas informações disponíveis sobre bombas e outros equipamentos rotativos, incluindo informações altamente especializadas sobre a análise de falhas e a determinação das causas-raiz.

Sem análises, um especialista em equipamentos rotativos precisará ser especialista em muitos tipos de equipamentos. Com os níveis reduzidos de pessoal, comuns em muitas fábricas, um especialista pode ser facilmente responsável por muitos ativos desconhecidos, possivelmente dispersos geograficamente. Talvez um operador ou um engenheiro

geral seja responsável pela solução inicial de problemas e só chame o especialista em casos terríveis.

O Analytics e o gêmeo digital oferecem uma maneira de fazer previsões sobre bombas e outros equipamentos rotativos. Essas previsões podem ser usadas para atualizar planos de manutenção, fazer mais manutenção em bombas de alto risco e menos manutenção onde o risco é menor. O Google Analytics pode aprender a reconhecer certos padrões que levam à falha, o que fornece novos insights não disponíveis em outras abordagens.



4.4 Desenvolvendo o Sistema

Organizamos a análise girando o tipo de equipamento e outros critérios, como serviço. Os cientistas de dados usarão o MindSphere Predictive Learning para desenvolver um ou mais algoritmos que fazem previsões sobre o desempenho da bomba, incluindo:

- Provável tempo de falha,
- Probabilidade de o ativo falhar ou precisar de manutenção em um determinado período, como nos próximos 30 dias,
- Causa mais provável da falha e razões da falha,
- Recomendações de manutenção.

Esses algoritmos são desenvolvidos - treinados - usando vários anos de dados históricos, incluindo:

Referência de equipamento - na maioria dos casos, são dados constantes ou descritivos.

- Condições físicas e mecânicas, como idade e design do equipamento
- Especificações, condições de projeto e curvas da bomba

Dados mecânicos - esses são principalmente dados transacionais.

- Comprimentos de execução e histórico de falhas

- Histórico de inspeção, serviço, manutenção e reparo

Dados de máquinas - na maioria, são dados de séries temporais ou podem ser convertidos para o formato de séries temporais.

- Status e serviço do equipamento
- Dados de vibração
- Uso, eficiência e eficiência da unidade

Dados operacionais - geralmente são dados de séries temporais ou podem ser convertidos para o formato de séries temporais.

- Condições do processo, como taxas de fluxo, temperatura, pressão, densidade e tipo de fluido, incluindo alterações fora das condições do projeto.

A análise é configurada através do mapeamento dos dados da planta da solução XHQ para as entradas do algoritmo e do mapeamento das saídas dos algoritmos para os itens na solução XHQ. A tabela mostra duas das muitas bombas e duas das muitas entradas e saídas de cada bomba.

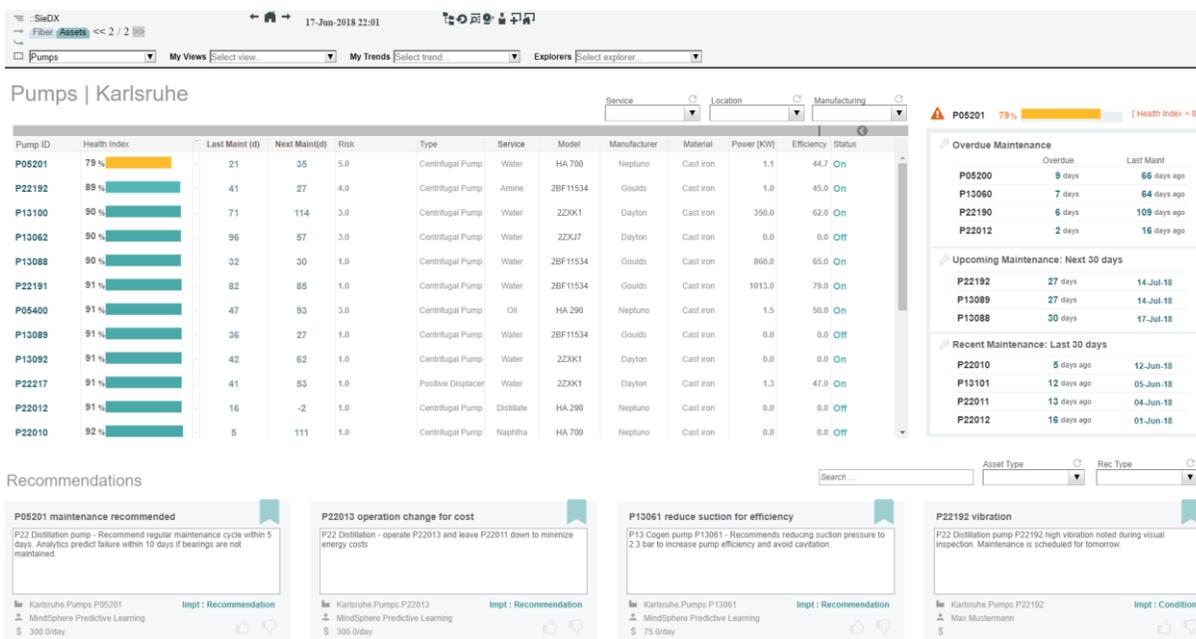
Bomba	Entrada de Algoritmo			Saída de algoritmo
	Pressão de sucção	Pressão de descarga	...	
10P-106A	10PI3957.PV	10PC3958.PV	...	:: Ativos... 106A
10P-106B	10PI3954.PV	10PC3938.PV	...	:: Ativos... 106B

O XHQ está configurado para mostrar informações resumidas sobre todas as bombas e detalhes para cada bomba. Essas informações incluem informações de projeto e dados mecânicos, de maquinário e operacionais atuais. Essas visualizações XHQ são estendidas para mostrar também os resultados das análises, incluindo previsões e indicadores de funcionamento de bombas individuais, o tempo provável até a falha, modos de falha e recomendações de manutenção.

4.5 Usando o Sistema

Todos os dias e em segundo plano, o XHQ executa os algoritmos de previsão de bombas no MindSphere Predictive Learning para cada bomba.

Para fazer isso, o XHQ reúne a entrada necessária, envia a entrada como arquivos para o data lake na nuvem usada pelo MindSphere, executa o algoritmo, aguarda a conclusão da tarefa, baixa os arquivos de saída para o servidor XHQ e lê os



resultados. Todo esse processo é na verdade um conector XHQ, e o processo de execução de algoritmos é invisível para os usuários. Os principais usuários são especialistas em equipamentos rotativos e engenheiros de processos. O algoritmo retorna um índice de integridade - um número -

para cada bomba, e talvez até mais detalhes. Os usuários veem essas novas informações nas visualizações XHQ, juntamente com todas as outras informações que o XHQ disponibiliza. Um índice de integridade com valores ruins acionará alertas e avisos.

Figura 4. Funcionamento do equipamento rotativo - visualização de todas as bombas

As pessoas usam essas informações para aumentar a integridade geral das bombas. Eles atualizam os planos de manutenção e inspeção, por exemplo, solicitando mais verificações do óleo lubrificante. Nos casos em que as análises preveem alto risco para bombas importantes, os engenheiros podem fazer alterações nas operações, alterar o programa de manutenção ou alterar o design.

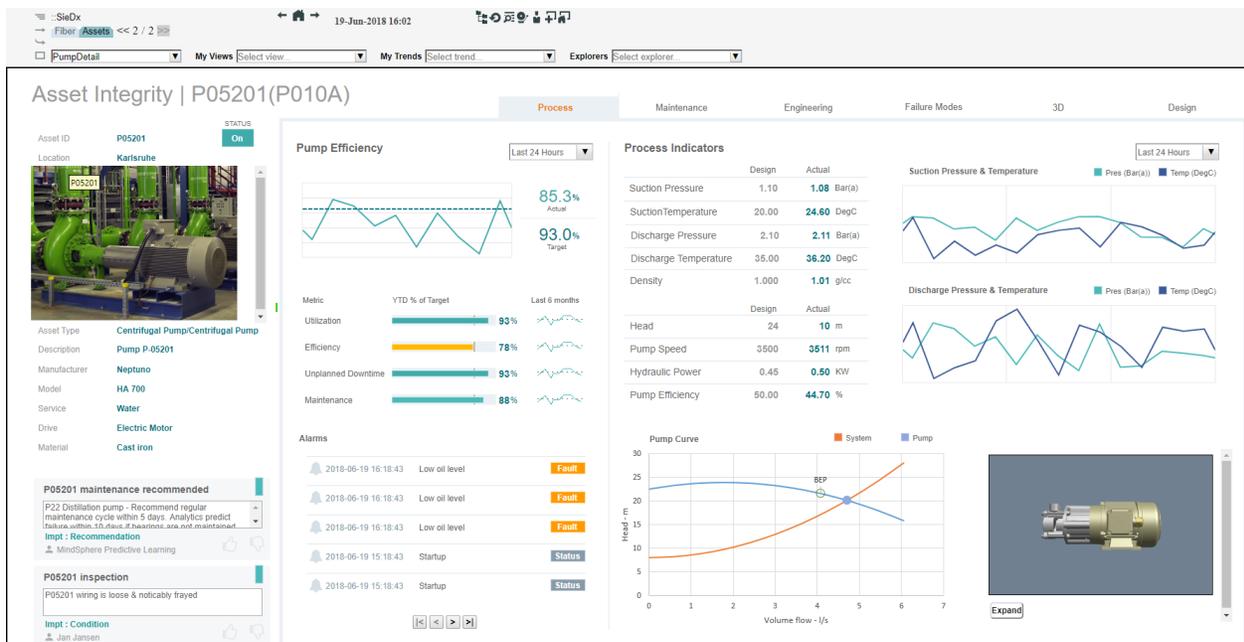


Figura 5. Funcionamento do equipamento rotativo - detalhes de uma bomba

O resultado final são bombas mais confiáveis e melhores previsões de quando a manutenção é necessária, o que reduz os custos de manutenção não planejados e melhora a confiabilidade da unidade.

5. Custos de Manutenção

O Analytics pode melhorar o estudo dos custos de manutenção, comparando gastos e resultados e destacando as áreas em que a manutenção pode ser reduzida ou deve ser aumentada.

5.1 Apresentação

Refinarias, fábricas de produtos químicos e outras instalações de processo exigem muitos ativos, e é necessária manutenção constante para manter o bom desempenho dos ativos. Um estudo da Solomon * constatou que uma planta de alto desempenho de US \$ 1 bilhão gasta de US \$ 12 a US \$ 20 milhões por ano em despesas de manutenção, enquanto os de baixo desempenho gastam duas a quatro vezes mais por ano.

Por exemplo, três refinarias semelhantes gastam diferentemente em manutenção. Parte disso é planejado e normal, mas as razões para algumas das diferenças não são claras. Um sistema que ajuda a ver por que os gastos com manutenção diferem e se gastar mais resulta em melhores resultados seria útil.

5.2 Objetivo

O objetivo do estudo de custos de manutenção é examinar os gastos e os resultados, para ver onde uma instalação pode estar gastando muito pouco ou muito, em relação ao desempenho da instalação.

5.3 Ideia

Um gerente de manutenção possui informações detalhadas sobre gastos com manutenção e confiabilidade da unidade. Ele gostaria de entender melhor como otimizar o trabalho de manutenção, minimizar custos e maximizar resultados.

Use análises avançadas para explorar os dados para obter informações, analisar para onde vai o dinheiro e procurar correlações entre gastos e resultados de manutenção, levando em consideração fatores como a idade das instalações, trabalho planejado e não planejado, etc.

5.4 Desenvolvendo o Sistema

Organizamos a análise observando informações detalhadas sobre gastos com manutenção e desempenho da planta. Os

cientistas de dados usam o MindSphere Predictive Learning para desenvolver insights sobre questões como:

- A relação entre a frequência de manutenção, e a confiabilidade e o desempenho
- Quaisquer áreas ou tipos de ativos em que seja feita muita ou pouca manutenção preventiva
- Os cronogramas de manutenção preditiva e preventiva mais eficazes

Esses insights são desenvolvidos usando vários anos de dados históricos, incluindo:

- Gastos por unidade de processo
- Gastos por especialidade (soldadores, eletricitistas, instaladores de tubos, etc.)
- Gastos por tipo de ativo
- Gastos por trabalho planejado versus não planejado
- Disponibilidade e confiabilidade da unidade

O resultado da análise são recomendações para otimizar a manutenção e novos KPIs que rastreiam até que ponto os gastos com manutenção correspondem ao ideal. O XHQ está configurado para mostrar esses novos KPIs.

5.5 Usando o Sistema

Ao desenvolver os insights, os principais usuários são gerentes de manutenção e especialistas em engenharia, que fornecem os dados, ajudam a identificar áreas de investigação, revisar os resultados e determinar a melhor forma de implementar as recomendações.

Depois que os KPIs foram incorporados ao XHQ, os principais usuários continuam sendo gerentes de manutenção e especialistas em engenharia, que terão um scorecard o quanto se aproxima a frequência do trabalho de manutenção daquele que pode ser considerado o melhor caso. Este scorecard pode ser incorporado às visualizações XHQ padrão.

* Estudo de 2013 Solomon RAM, Solomon Associates, LLC.

6. Dados não estruturados

O Analytics pode melhorar a usabilidade de dados não estruturados, especialmente texto, detectando informações ocultas e facilitando a consulta.

6.1 Apresentação

Refinarias, planos químicos e outras instalações de processo têm relatórios de turnos para cada posição e turno operacional. Os relatórios de turnos geralmente são uma mistura de texto inserido por um operador, e outras informações. Além disso, muitas aplicações software permitem inserir comentários, por exemplo, sobre violações de limites operacionais, motivos para alterar metas ou observações durante uma inspeção. Uma refinaria com dez consoles, cinco posições de campo e turnos de 12 horas terá 30 relatórios de turno todos os dias e pode gerar facilmente centenas de notas e comentários todos os dias. Essas notas e comentários geralmente são concisos e podem usar nomes diferentes para se referir à mesma coisa.

Essas notas podem fornecer informações sobre as operações, mas encontrar as notas certas pode ser difícil quando os nomes estão incorretos ou são usados apelidos. Ajudaria se o sistema possibilitasse a descoberta rápida da informação necessária.

6.2 Objetivo

O objetivo da análise de dados não estruturados é facilitar a localização de informações em texto, independentemente de como elas possam ter sido inseridas originalmente.

Por exemplo, o relatório de turno de uma unidade específica pode ter comentários como esse por um período de anos, todos se referindo a problemas com o tambor de refluxo D-208 na unidade de destilação bruta:

<i>Data</i>	<i>Comentário</i>
2018	<i>D208 volta a ficar online após WO 6132245</i>
2017	<i>Observado vazamento do cilindro</i>
2015	<i>Observações do tambor do condensador ATM</i>
2013	<i>Bota D208water conectada, nivelada</i>
2012	<i>Aumentar amina para D-208</i>
2012	<i>SOL em D208 ph</i>

O objetivo é facilitar a busca por todas as referências a esse tambor.

6.3 Ideia

Primeiro, desenvolva algoritmos para processar comentários não estruturados, como entradas de registros do operador, e encontre informações relevantes, como nomes de ativos.

Depois, execute esses algoritmos em todos os comentários registrados nos eLogs e atualize os comentários (ou metadados) com dados que facilitam a pesquisa.

Por exemplo, os comentários do relatório de turno podem ser atualizados para adicionar uma associação ao ativo que usa um nome comum para o tambor de refluxo.

<i>Data</i>	<i>Comentário</i>	<i>Ativo</i>
2018	<i>D208 volta a ficar online após WO 6132245</i>	<i>D-208</i>
2017	<i>Observado vazamento do cilindro</i>	<i>D-208</i>
2015	<i>Observações do tambor do condensador ATM</i>	<i>D-208</i>
2013	<i>Bota D208water conectada, nivelada</i>	<i>D-208</i>
2012	<i>Aumentar amina para D-208</i>	<i>D-208</i>
2012	<i>SOL em D208 ph</i>	<i>D-208</i>

6.4 Desenvolvendo o Sistema

Os especialistas no assunto fornecerão uma lista de termos padrão a serem encontrados, como nomes de ativos, nomes de unidades e nomes de produtos.

Os cientistas de dados usarão o MindSphere Predictive Learning para desenvolver **algoritmos de análise de texto** que analisam todos os comentários nos eLogs, juntamente com os metadados desses comentários, como a data, a pessoa que inseriu o comentário e as informações associadas.

Registro de Inclusão

Event Date	03/14/18 01:59:26 am	Log Type	Production	User	indx1\jimchristian
Priority	Medium	Log SubType	GENERAL	XHQ Path	...
Short Text	D208 online				
Long Text	D2018 back online after WO 6132245				

Como o sistema identifica termos padrão, ele adiciona uma associação à entrada eLogs. Como alternativa, ele pode usar outra abordagem para vincular termos padrão à entrada do log.

O resultado da análise é atualizar muitas entradas de eLogs com referências a ativos, unidades, produtos e outros termos padrão, de forma que um usuário possa pesquisar usando os termos padrão.

A solução XHQ pode ser atualizada para fornecer opções para pesquisar nos eLogs usando os termos padrão.

6.5 Usando o Sistema

Todos os dias e em segundo plano, o XHQ executará os algoritmos de análise de texto para processar novos comentários. Isso é invisível para os usuários.

Os principais usuários incluem a maioria dos engenheiros e gerentes.

Esses usuários terão à sua disposição formas novas e aprimoradas de pesquisar entre os comentários inseridos nos eLogs. As novas opções de pesquisa para facilitar a inserção de "D-208" e encontrar todos os comentários que se referem a esse ativo, no entanto, o nome do ativo pode ter sido digitado nos comentários originais. (Pode ser possível permitir a pesquisa por variações, por exemplo, para permitir que "D-208", "D208" e "atm condenser drum" sejam reconhecidos como sinônimos de "D-208".)

Software de Inteligência Operacional XHQ
Siemens Digital Industries Software
DI PA AE CIS XHQ
Rua Niterói, 400 – 7º Andar
São Caetano do Sul, SP – Brasil

info.br.xhq@siemens.com

siemens.com.br/xhq

Todos os direitos reservados. Todas as marcas registradas usadas pertencem à Siemens ou a seus respectivos proprietários.