

SISTEMA DE INTELIGÊNCIA ARTIFICIAL PARA MONITORAMENTO DO PROCESSO DE SECAGEM E PREVENÇÃO DA QUEBRA DE FOLHAS

Salvador Flores¹, Manuel Pérez², Cristian Chandia³

¹ Empresas CMPC. salvador.flores@cmpec.cl, Chile

² Unidade de Data Science. Universidad de Concepción. maperezc@inf.udec.cl, Chile

³ CMPC Pulp. cchandia@celulosa.cmpec.cl, Chile

RESUMO

O quebra de folha no processo de secagem de uma fábrica de celulose é um problema em aberto devido à complexidade e dinamismo do processo, bem como à raridade desses eventos, o que dificulta a obtenção de dados para decifrar suas variadas origens. Em resposta a este problema, foi desenvolvido um sistema de análise avançada que combina um modelo de Inteligência Artificial e controle estatístico para monitorar o processo de secagem na fábrica de celulose de Santa Fé (Chile), antecipando anormalidades operacionais que, se não gerenciadas, podem gerar perturbações significativas, até mesmo um quebra de folha. Este trabalho acompanha as últimas tendências na organização de equipes de *advanced analytics* e na utilização de Inteligência Artificial para detectar anomalias em grandes volumes de dados. Com isso, é possível identificar a condição anômala anterior aos quebras foliares ocorridos em 2023 com tempo médio de antecipação de 80 minutos. O sistema foi validado com dados históricos e também foi desenvolvido um MVP (produto mínimo viável), o que permitiu apoiar, em conjunto com os operadores, a utilidade do sistema para ter um processo de secagem otimizado alavancado na utilização de dados. Graças ao trabalho conjunto da academia e da fábrica de Santa Fé com engenheiros, operadores e gestores de área envolvidos e comprometidos com o sucesso do projeto, foi realizado um conjunto de validações para garantir a qualidade do Sistema de Inteligência Artificial desenvolvido; e, como existe uma confiança elevada, permite-nos dar o próximo passo é desenvolver um produto analítico inovador, cada vez mais robusto, eficaz e replicável nas restantes fábricas de pasta.

Palavras-chave: *Inteligência Artificial, redes neurais, controle do processo, processo otimizado, quebra de folha*

INTRODUÇÃO

A detecção de quebras de folhas em uma máquina de secagem de uma fábrica de celulose é um procedimento muito difícil devido à complexidade do processo, à sua rapidez e também

ao fato de ser um processo muito dinâmico no qual a distribuição dos dados varia com a menor alteração nos componentes da máquina. Por tais razões, é um problema que permanece em aberto, apesar dos repetidos esforços para o resolver.

A Linha 2 da planta de Santa Fé produz cerca de 3.600 Adt/d, sendo a maior planta de celulose das Empresas CMPC no Chile. Em 2022, 7,7% do total de perdas de produção registradas nesta fábrica foram devido a quebras de folhas, muitos deles relacionados com razões operacionais previsíveis por meio da utilização de dados.

Para enfrentar com sucesso este desafio, foi realizado um trabalho conjunto entre a área de *advanced analytics* das Empresas CMPC de mãos dadas com a fábrica, envolvendo todos os operadores de sala, além do gerente de turno e chefe da unidade de Secagem no mapeamento de variáveis que afetam o quebra de folhas. Por outro lado, houve também apoio da gestão de melhoria contínua, gestão de operações e gestor de fábrica. Esse apoio é fundamental, já que um projeto como esse exige muito tempo de especialistas da área para ter sucesso.

Na fábrica de Santa Fé, como em muitas fábricas de celulose, a área de operações de secagem fica em um prédio diferente do prédio de operações onde funciona o restante da planta. Essa distância física faz com que as transformações digitais permeiem menos nesta área do que no restante da planta, o que os torna mais relutantes e mais hesitantes em aceitar o uso de novas ferramentas e o trabalho colaborativo com áreas de apoio da empresa, gerando uma maior resistência à mudar.

O desenvolvimento do sistema de Inteligência Artificial para prevenção de quebras de folhas foi realizado de forma iterativa, mapeando variáveis, entendendo o processo e testando múltiplos modelos até que seu correto desempenho fosse validado e depois validado com a planta através do desenvolvimento de múltiplos MVPs (Produtos Mínimos Viáveis), para finalmente garantir a qualidade técnica e o impacto comercial do produto desenvolvido.

MÉTODOS

Para detectar quebras de folhas na secadora, é utilizado um sistema de IA que monitora conjuntamente 96 variáveis do processo de secagem para identificar se a distribuição conjunta dos dados varia de uma condição normal para uma condição não vista antes pela máquina. sistema ou uma condição na qual ocorreu um quebra na lâmina. Neste último caso, é identificado como uma condição anormal. Para mostrar de forma concisa esta condição conjunta do processo, é criada uma pontuação de anomalia que, como o próprio nome indica, mostra o quão anômalo é o processo de secagem com dois limites diferentes para indicar um alerta de gravidade média ou um alerta grave. Quanto maior a severidade do alerta, mais desviado é o processo de secagem e, portanto, há maior risco de ocorrer quebra de folhas.

Essa lógica se baseia na hipótese de que se a secagem estiver operando com condição diferente das condições históricas de operação normal, a possibilidade de ocorrer algum problema no processo que possa desencadear o quebra da folha é muito maior. É importante notar que não existe uma “linha central” ou uma condição normal única; o sistema é capaz de distinguir uma condição anômala entre condições operacionais muito diversas que não estão associadas ao quebra da lâmina.

Para que uma ferramenta apoie verdadeiramente a tomada de decisões e previna eficazmente o quebra de folhas, são necessários pelo menos dois componentes:

- Um alerta oportuno, com antecedência suficiente para que ações possam ser tomadas.
- Um guia de localização da causa do problema, que fornece informações úteis ao operador para decidir as ações necessárias.

No futuro, a ferramenta poderá dar instruções ao operador sobre quais ações tomar para evitar a quebra da lâmina.

No momento em que é gerado um alerta de anormalidade no processo, é necessário saber quais variáveis estão se desviando e por quê. Para tanto, são gerados dois *rankings* de variáveis desviadas onde são analisados os desvios de curto e longo prazo.

1. Coleção de dados

Primeiro, por meio de um processo iterativo, foram mapeadas um total de 96 variáveis do processo de secagem desde o TAC Branco até o Secador, que, com base na experiência e conhecimento técnico do processo, são as que têm maior impacto na desestabilização do processo. e gerar um quebra de folha. Este mapeamento foi realizado em conjunto com os cinco operadores de sala, dois chefes de área e o chefe de unidade por meio de múltiplas rodadas de entrevistas.

Depois de identificadas todas as variáveis do processo, é necessário identificar quais condições do processo

são consideradas anormais e quais condições são consideradas operação normal. Isso porque a ideia central é poder treinar o sistema de inteligência apenas com dados normais de operação, para que quando ele vir dados de operação anômalos possa detectá-los. Nos registros de processo existem múltiplos registros de incidentes, como problemas em alguma outra área da planta que impactam no processo de secagem (problemas de qualidade do vapor, por exemplo), problemas com fardos na cortadora, algum evento de falha em alguma parte da máquina, e paradas de processo, sejam elas não programadas por quebra de folhas, paradas não programadas por falha em outra área da planta, bem como paradas programadas de processo. Adicionalmente, existem outras condições excepcionais do processo que podem ser identificadas por intermédio de variáveis, essas condições são, principalmente, duas: recirculação e rejeições.

2. Processamento de dados

Os dados utilizados correspondem ao período de janeiro de 2022 a maio de 2023 com granularidade de 5 minutos. Somente a limpeza de dados é realizada com foco em suavizar sinais muito ruidosos e eliminar erros claros de medição do sensor. Não é realizada nenhuma limpeza adicional dos dados, pois como o foco do problema é a detecção de anomalias, os dados devem ter apenas as limpezas necessárias para que o modelo consiga identificar padrões atípicos nos dados. Isso evita que o sistema gere alertas em condições normais de processo, simplesmente por falhas na comunicação de dados.


3. Sistema de Inteligência Artificial

O sistema de IA é composto por dois modelos diferentes, em que a saída de um corresponde à parte da entrada do outro modelo.

Primeiro, são obtidas múltiplas janelas de intervalos de tempo que representam uma observação do processo. Ou seja, são analisadas as variações de última hora do processo e, com base nisso, é treinado um conjunto de modelos para identificar se a condição atual do processo de secagem é anômala ou não.

Após a separação dos dados em janelas, é calculado um modelo autorregressivo, que permite obter as relações entre todas as variáveis do processo e compreender o DNA dos dados.

Posteriormente, a matriz dos pesos do modelo autorregressivo, juntamente com o cálculo de diferentes estatísticas na janela de dados, como média, variância, mínimo e máximo, são inseridos em um autoencoder composto por múltiplas camadas densas totalmente conectadas para reduzir o espaço dimensional e posteriormente reconstruir os dados como a saída do autoencoder.



Pontuação de anomalia e aviso

O sistema de IA é composto por dois modelos diferentes, onde a saída de um corresponde à parte de entrada do outro modelo.

Primeiro, são obtidos vários gráficos de intervalos de andamento que representam uma observação do processo. Acontece que apenas as variações de última hora do processo foram analisadas e um conjunto de modelos foi treinado para identificar se a condição atual do processo de secagem era anormal ou não.

Depois de separar dois dados em janelas, é calculado um modelo autorregressivo, que permite obter as relações entre todos os processos variáveis e compreender o ADN dos dois dados.

Posteriormente, a matriz de dois pesos do modelo autorregressivo, juntamente com o cálculo de diferentes estatísticas na tabela de dados, como média, variância, mínimo e máximo, são inseridas em um autoencoder composto por múltiplas camadas densas totalmente conectadas para reduzir o dimensional espaço e, posteriormente, reconstruir os dados como saída do autoencoder.

Classificação de curto prazo

A classificação de curto prazo concentra-se na variabilidade do processo em relação ao cenário operacional estável mais próximo. A variabilidade de curto prazo é obtida por meio da com-

paração da integral entre o período de estabilidade e o período de comparação. Então, com a diferença entre as áreas sob a curva, é possível saber quais variáveis têm maior variação e, calculando um limite com base em com base nas variações históricas, pode ser gerada uma classificação da variabilidade de curto prazo.

Classificação de longo prazo

A classificação de longo prazo concentra-se nas variações da média dos dados num horizonte temporal mais longo, comparando os últimos 30 dias. Com base neste período de tempo são calculados a média e o desvio padrão dos dados e gerados limites para identificar três faixas de desvio dos dados para identificar variáveis desviadas com alerta médio ou alto.

Validação de ferramenta

Para validar a ferramenta é necessário um processo iterativo que valide off-line a qualidade do modelo. Esta validação centra-se na capacidade do modelo de identificar quebras de folhas, avaliar o tempo antecedente (momento em que as quebras de folhas podem ser antecipadas) e o número de falsos positivos (alertas que não representam realmente um problema). As métricas de validação off-line são apresentadas abaixo:

CAPACIDADE DE DETECTAR CORTES DE FOLHAS		PERFORMANCE GLOBAL		
TAXA DE ACESSO	TEMPO ANTECEDENTE MÉDIO	TAXA DE ALERTA DE ANOMALIA OPERACIONAL	DURAÇÃO MÉDIA DOS ALERTAS ANOMALIAS	TIEMPO DE TELÓN (SISTEMA FUERA DE SERVICIO)
62,5% de precisão de cortes de folhas definidos como detectáveis sob avaliação de especialistas	82,5 minutos antes do quebra das folhas	66,67% dos alertas correspondem a alguma circunstância de recirculação, baixa velocidade e/ou rejeição 33,33% dos alertas correspondem a falsos positivos	39.8 minutos	4.69% del tiempo

MVP - Detector de corte de folhas - Santa Fe L2

Últimas 8 horas


ALERTA
alta

Telón ▾

Desactivado

Última actualización ▾

21 sept 2023, 14:35:00



Ranking de variabilidade
(corto plazo)

Fecha estable (referencia) ▾
21 sept 2023, 12:50:00

Variable	TAG	Etap	Valor	Diferencia
6. CNTL DE FLUJO TK2 P BLA TK MIX	250FIC 032.MEAS	TAC BLANCA	1234.689	Moderado
7. CORRIENTE BOMBA TK MEZCLA 2300101	250230 0101IIL PNT	TORRE RECORTE	0.01225362	Muy alto
8. DIFERENCIAL DE PRESION HARNERO TERCARIO	250PDI T166.P NT	DEPURAC IÓN	25.8179	Normal
9. CONTROL ABERTURA VALVULA VAPOR 514A	250PV 514A.O UT	SECADOR	24.15866	Moderado
10. CONTROL ABERTURA VALVULA VAPOR 514B	250PV 514B.O UT	SECADOR	24.15866	Moderado

Ranking de diferencias significativas
(largo plazo)

Variable	TAG	Etap	Valor	Desviación	Mínimo	Máximo
3. CAJA PAÑO SUPERIOR 1RA MEDIDA PRES	250PIT7 24.PNT	SISTEMA DE VACIO	-0.1799 219	Moderado	-0.305	-0.151
4. PRESION VAPOR SECADOR	250PIT5 50A.PNT	SECADOR	-170.02 77	Muy alto	-160.036	-93.025
5. PRESION INTERNA AIRE SECADOR	250PIT5 50.MEAS	SECADOR	-170.04 29	Muy alto	-160.4	-92.547
6. DAMPER 1 - EXTRACCION AIRE SECADOR	250HV5 27.OUT	SECADOR	94.931 29	Alto	31.148	100.766
7. DAMPER 2 - EXTRACCION AIRE SECADOR	250HV5 27.OUT	SECADOR	94.931 29	Alto	31.676	100.416

Após a validação off-line e garantindo a qualidade técnica do modelo, é necessário desenvolver um Produto Mínimo Viável (MVP) que permita ao usuário ver ao vivo a funcionalidade da ferramenta e assim analisar os alertas gerados, analisar se eles fazem sentido, as causas raízes que alertam o sistema e permitem ao operador da sala dar *feedback* sobre o sistema e ter ciclos iterativos de melhorias. No momento de colocar em operação o MVP desenvolvido, foram realizados uma série de treinamentos para cada um dos turnos de sala, campo e equipe líder, além de realizar acompanhamento diário para validar dúvidas, esclarecer funcionalidades da ferramenta e reforçar a relação colaborativa entre a área analítica e a planta. (imagem acima)


Como último passo antes da produtivização da ferramenta, para validar corretamente a funcionalidade da ferramenta, é realizado um breve inquérito aos utilizadores para que seja escrito e realizado um exercício final para compreender a utilidade da ferramenta. Após esta última verificação e tendo validado a funcionalidade da ferramenta é garantido que

ela gera impacto na operação, passamos a desenvolver um produto mais robusto que reduza o atraso na execução do sistema, calcule seus KPIs de desempenho e gere gráficos interativos. Esta aplicação é totalmente operacional na nuvem e é atualizada ao vivo com os dados da planta com frequência de 5 minutos e atraso de menos de um minuto.

RESULTADOS E DISCUSSÃO

Em relação às métricas técnicas do modelo, presentes na tabela anexa, é possível ver três grupos de métricas, o primeiro grupo, métricas do modelo, foca apenas nas métricas técnicas de treinamento da rede neural; o segundo grupo foca em métricas diretamente relacionadas à detecção de quebras de folhas (kpis do negócio que se pretende impactar), que contém a taxa de sucesso de detecção de quebras de folhas e o tempo médio de antecipação dos mesmos; por fim, o grupo de desempenho do sistema detector, que possui métricas complementares às anteriores,

Métricas do modelo		Métricas de detecção		Sistema Detector de Desempenho	
Treinamento	Teste	Taxa de acerto	Tempo médio de precedência	Tempo médio de duração do alerta	Tempo do sistema fora de serviço
Loss: 0.000239	Loss: 0.000477	62.5% de precisão nos cortes de folhas definidos como detectáveis	82.5 minutos antes do corte das folhas	39.8 minutos	4.69% das vezes



são elas a duração média dos alertas, o tempo em que o sistema fica fora de serviço e o número total de alertas do sistema para identificar o número de alertas de falsos positivos.

CONCLUSÕES

O desenvolvimento desta ferramenta é um exemplo claro de que é possível desenvolver aplicações de Inteligência Artificial em trabalho conjunto entre uma área de *advanced analytics* apoiada por fábricas. Se uma das duas áreas não tivesse contribuído com a sua parte, não teria sido possível desenvolver um produto de sucesso que nos permitisse antecipar o quebra de folhas.

Este produto completou a primeira etapa aqui apresentada após um ano e meio de trabalho, isso representa o grau de dificuldade e porque é um problema ainda sem solução em muitos contextos.

Após alguns meses de utilização, esta ferramenta tem sido alvo de melhorias frequentes, o que não significa que seja um produto totalmente acabado, longe disso.

A melhoria é a única constante neste caminho.

AGRADECIMENTOS

Em primeiro lugar, agradecemos à equipe de Competitividade da Fábrica das Empresas CMPC pelo apoio durante o desenvolvimento deste projeto, especialmente ao Gerente de Competitividade da Fábrica, Matías Jory. Destacamos também o apoio da fábrica de Santa Fé: Guilherme Domingos, Franco Herrera, Ricardo Gonzalez, Hector Bastidas, patrocinadores do projeto e agradecemos ao apoio dos operadores de secagem que sem essa ajuda, boa disposição e *feedback* constante, este projeto não poderia ter sido realizado: Marco Reyes, Marcelo Godoy, Alejandro Fernández, Héctor Erices, Leonel Sánchez. Por último, mas não menos importante, destacamos a contribuição da equipe de ciência de dados da unidade de ciência de dados da Universidade de Concepción para o desenvolvimento deste caso: Guillermo Cabrera, Valentina Hernandez, Ricardo Hernandez, Esteban Medina. ■