

# PREDIÇÃO DE QUALIDADE BASEADA EM MACHINE LEARNING \*

Jérémy Coppe<sup>1</sup>  
Elena Samuylova<sup>2</sup>  
Marcos Queiroz<sup>3</sup>

## Resumo

Na indústria siderúrgica quantidades de até 5% das peças produzidas precisam ser total ou parcialmente sucateadas devido a defeitos de qualidade. A maioria dos defeitos encontrados é relacionada com etapas iniciais do processo produtivo, mas estes defeitos são mais frequentemente encontrados nos produtos finais. E muitas perdas poderiam ser evitadas se defeitos fossem descobertos em etapas preliminares através de ações como, por exemplo: mudança da rota de produção do material, adaptação de parâmetros de processos, ou inclusão de etapas corretivas. Contudo, a quantidade de dados a serem analisados torna impossível para especialistas de qualidade previrem estes defeitos, e para isso criamos modelos matemáticos complexos que correlacionam os defeitos com milhares de dados de máquina e de processo evoluindo ao longo do tempo. Adicionalmente, uma maneira prática de se aplicar esse modelo de previsão de qualidade é o de se definir um conjunto de ações para todas as peças consideradas suspeitas de conterem um defeito. Para isso ser efetivo precisamos adicionalmente definir o limite da probabilidade do defeito a partir do qual as ações serão tomadas, e esse limite deve levar em conta o custo da ação corretiva em comparação com a probabilidade e o custo do defeito.

**Palavras-chave:** Machine Learning; Qualidade; Dados; Defeitos;

## MACHINE LEARNING BASED PREDICTIVE QUALITY

### Abstract

In the steel industry quantities of up to 5% of the pieces produced need to be totally or partially scrapped due to quality defects. Most of the defects found are related to the early stages of the production process, but these defects are most often found in the final products. And many losses could be avoided if defects were discovered in preliminary stages through actions such as: changing the production route of the material, adapting process parameters, or adding corrective steps. However, the amount of data to be analyzed makes it impossible for quality specialists to predict these defects, and for this complex mathematical models have been created, correlating defects with thousands of machine and process data evolving over time. In addition, a practical way of applying this quality prediction model is to define a set of actions for all the pieces considered suspected to contain a defect. For this to be effective we need to further define the probability threshold of the defect from which the actions will be taken, and this threshold must take into account the cost of the corrective action in comparison with the probability and cost of the defect.

**Keywords:** Machine Learning; Quality; Data; Defects.

<sup>1</sup> *Bachelor in Engineering Sciences, Applied Mathematics and Mechanics, Master in Mathematical Engineering, Supply Chain Consultant and R&D Analyst at PSI Metals Belgium, Brussels, Belgium.*

<sup>2</sup> *Specialist in Economics, Master in Interational Business, Chief Product Officer at Mechanica AI, Amsterdam, Netherlands.*

<sup>3</sup> *Engenheiro de Produção, Especialização em Administração de Negócios, Diretor de Vendas da PSI Metals para a América Latina, São Paulo, SP, Brasil.*

## 1 INTRODUÇÃO

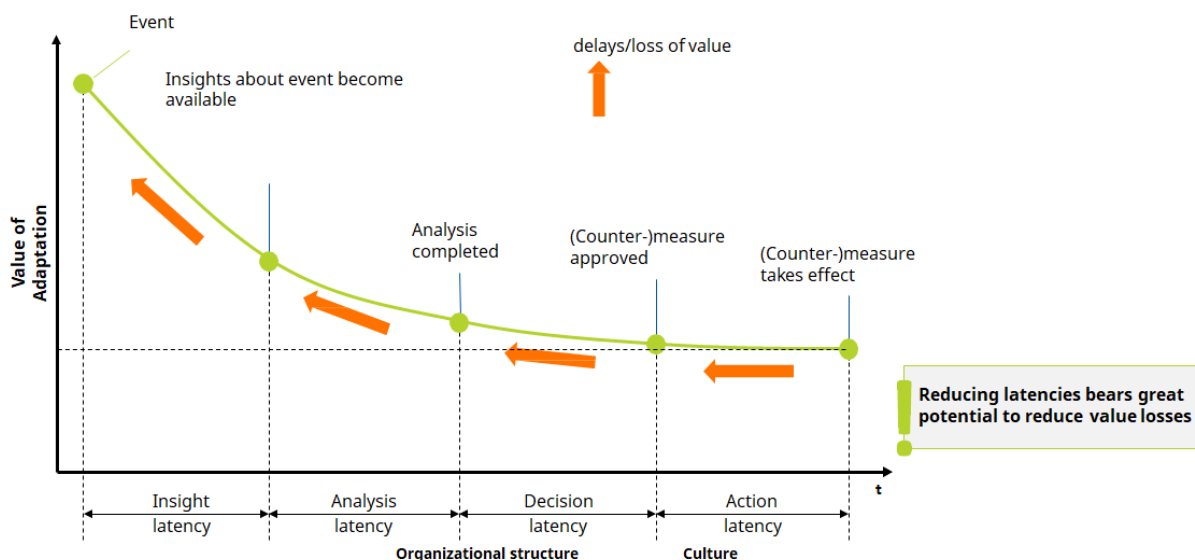
Este trabalho descreve os avanços que têm sido feitos e ganhos que têm sido obtidos com a aplicação de novas tecnologias de computação cognitiva, inteligência artificial, e análise de grandes volumes de dados no estabelecimento de correlações entre condições operacionais e o surgimento de defeitos em peças produzidas no processo siderúrgico.

O estudo de caso foi aplicado em eventos ocorridos em um laminador de tiras a quente com defeitos percebidos em bobinas processadas posteriormente em diversas linhas.

Em muitas ocasiões, eventos não planejados podem ser correlacionados com defeitos e normalmente como consequência alguém precisa reagir e tomar uma ação. Porém o caminho para se decidir sobre a ação a ser tomada tipicamente é longo e difícil, e composto por diversas fases:

- 1) A fase de insight: período em que se confirma que o evento ocorreu
- 2) A fase de análise: período em que se entende o que ocorreu e as causas
- 3) A fase de decisão: período em que se decide o que deve ser feito e quais ações devem ser tomadas
- 4) A fase de ação: período em que se tomam as medidas para endereçar os problemas causados pelo evento

Quanto mais crítico o evento e quanto mais longo o tempo entre reconhecimento da ocorrência e tomada de ação, mais valor é potencialmente perdido, e encurtar esse tempo é algo que traz grande potencial de redução de perdas.



**Figura 1.** Reação a eventos não planejados

É nesse ponto que os conceitos de computação cognitiva e algoritmos avançados aplicados em análise de Big Data mostram um importante valor: melhorando a assertividade das fases que compõem o tratamento de eventos inesperados e encurtando o tempo entre o evento e a ação que o endereça.

Adicionalmente, esses novos conceitos e tecnologias, permitem a mudança da tomada de decisão de um ponto em que ela é reativa e focada em correção de

situações passadas, para um ponto em que ela é proativa e baseada na expectativa probabilística de eventos futuros.

## 2 DESENVOLVIMENTO

Sistemas de monitoramento de produção em tempo real e integrados melhoram a habilidade em se obter os insights de modo que se aprenda em curto espaço de tempo quando algo acontece em um processo produtivo, no caso do nosso estudo em um laminador de tiras a quente.

A análise avançada de dados, o chamado “Machine Learning” e a inteligência artificial permitem uma análise mais eficiente de problemas complexos baseada em dados de processo acumulados.

Com a correta representação de eventos em um conjunto de dados históricos, somos capazes de dar suporte a decisões de operadores ou até mesmo automatizar essas decisões de maneira completa. E adicionalmente, sistemas integrados tanto horizontal quanto verticalmente podem permitir a tomada de ações através de fronteiras organizacionais sem quaisquer atrasos.

Cada segundo economizado dessa maneira tem potencial de aumentar a eficiência do processo produtivo através de tomadas de decisão mais precisas, baseadas em valores otimizados de parâmetros de processo, rotas de produção, e assim por diante.

O nível de digitalização tipicamente encontrado nas empresas nas diferentes fases descritas em nossa introdução é significativamente diferente:

- 1) Insight: na fase de insight o reconhecimento de que algo aconteceu pode ser atingido através de um alto nível de automação através da obtenção de dados por sensores (com os sistemas integrados de gestão de manufatura exercendo um papel fundamental);
- 2) Análise: nesta fase o processo que se observa na maioria das empresas ainda hoje ainda é bastante manual e estático;
- 3) Decisão: as decisões sobre ações de qualidade ainda são majoritariamente tomadas por pessoas com algum suporte dos resultados de análise e sistemas com funções baseadas em regras simples. Frequentemente, a qualidade de decisões depende da experiência ou até mesmo da intuição de operadores ou especialistas;
- 4) Ação: as ações são tipicamente suportadas por ferramentas de automação industrial e integração clássica com outros sistemas

Os maiores ganhos podem ser obtidos ao se transformar a camada de tomada de decisões. Com base em análises de dados de processo acumuladas, é possível mudar a tomada de decisões baseada em regras ou em especialistas para uma tomada de decisões mais “personalizada” e automatizada, com base em métodos avançados de análise.

Com os sistemas de coleta de dados e execução de decisões já implementados, os ganhos operacionais podem ser alcançados com o mínimo de esforço, o que torna o Machine Learning uma área de foco atraente como parte dos componentes da Indústria 4.0.

### 2.1 Big Data na produção siderúrgica

A digitalização do processo de manufatura traz uma quantidade enorme de dados digitais obtidos através de sensores, controles de produção, controles de qualidade, genealogia de materiais, logs de materiais, logs de processos, controle de desgaste de equipamentos, dados de manutenção, e assim por diante.

A maioria das pessoas acredita que nós já coletamos mais dados do que conseguimos armazenar, processar e entender, e este volume só tende a aumentar. A verdade é que a maioria das indústrias ainda não sabe como fazer o uso correto de todos esses dados.

As indústrias geralmente coletam os dados da maneira como eles são oferecidos, e os armazenam em uma base de dados aonde eles são deixados sem que sejam examinados ou analisados posteriormente. E quanto mais avançados os sistemas de automação, maior o potencial do volume de dados a ser coletado.

Mas o nível de automação e volume de dados eles são usados apenas ocasionalmente para resolução de incidentes, muitas vezes reclamações tardias de cliente, e em casos raros para algumas análises agregadas de alto nível. As empresas vão tipicamente acessar e examinar o volume desses dados quando um administrador de banco de dados questiona se todos os dados coletados são realmente necessários ou se é possível reduzir o espaço que eles ocupam. E isso tem se tornado cada vez menos frequente com as frequentes reduções dos custos de armazenamento de dados.

Ao mesmo tempo, esses mesmos registros de produção já podem se tornar uma valiosa fonte dos chamados “dados de treinamento” para algoritmos de Machine Learning. Embora muitas iniciativas de Internet das Coisas (IoT) [1] se concentrem na instalação de novos sensores para coletar e transmitir mais dados sobre processos de produção em andamento, muitas vezes faz sentido iniciar o processo de digitalização observando os dados já coletados pelos sistemas de controle de processos existentes. Dessa forma, as empresas podem aproveitar mais a onda de automação anterior e, aplicando novas tecnologias de inteligência artificial e Machine Learning, atingem melhorias de negócios tangíveis sem grandes custos de capital ou mudanças nos processos.

## 2.2 O contexto dos defeitos de qualidade

Cada um dos parâmetros de produção e equipamento mencionados anteriormente e muitos outros não listados aqui podem afetar a ocorrência de defeitos de aço. Desvios de cada parâmetro podem ter um impacto crítico na qualidade geral do produto final e, em muitos casos, é muito difícil determinar qual combinação de parâmetros causou qual defeito.

Certos casos e desvios de processo, evidentemente, tornam-se claros com bastante facilidade e são revelados imediatamente. Ao mesmo tempo, uma porção significativa de defeitos pode ser atribuída a razões menos aparentes e uma combinação de vários fatores “mais fracos” agindo em conjunto.

Com limitações nas medições (por exemplo, devido a ambientes de alta temperatura) e algumas fontes de dados ausentes (por exemplo, se placas de aço são compradas externamente e o fornecedor não possui informações completas sobre parâmetros de lingotamento), defeitos menos aparentes nem sempre podem ser revelados a tempo, e suas causas não deveriam ser descartadas ou substituídas por alguma abordagem direta.

A fabricação com defeito zero ainda é impossível para a maioria das indústrias hoje em dia. Taxas de defeitos de 5% ou mais não são exceção para a produção siderúrgica, mesmo em nosso mundo digital de fabricação, com processos de produção altamente automatizados e de qualidade monitorada.

Os procedimentos de teste e de controle de qualidade são muito caros e formam uma parte significativa do custo total de produção, portanto, não podem ser aplicados com escrutínio e máximo nível de detalhes a todos os materiais.

A disponibilidade de dados e técnicas avançadas de análise abrem novas oportunidades para reduzir ainda mais a taxa de defeitos de forma significativa. Esses dados devem permitir que o processo de gerenciamento da qualidade seja capaz de prever defeitos em um estágio inicial do processo de produção.

A maioria dos defeitos está relacionada aos estágios iniciais do processo de produção (lingotamento e laminação), mas muitas vezes descobertos apenas nas etapas de acabamento do produto. Os defeitos detectados tardiamente (os chamados "defeitos ocultos") acarretam custos significativos devido a etapas de produção desnecessárias, bem como atrasos de entrega, pois esses pedidos podem ter que ser atendidos iniciando uma nova sequência de produção com um novo material.

Se os defeitos puderem ser previstos antecipadamente, a maioria deles poderia ser evitada adaptando-se a rota ou processo de produção restante, processo chamado manuseio de defeitos. No caso de certos defeitos não poderem ser tratados, um material pode ser rebaixado para um pedido diferente e um novo material iniciado antecipadamente para atender ao pedido atual. Uma abordagem proativa para o tratamento de defeitos com base em previsões tem o potencial de melhorar drasticamente a eficiência da produção de modo geral.

### 2.3 Modelagem Preditiva

As tecnologias de Machine Learning podem explorar exhaustivamente todas as combinações possíveis de como os fatores de produção afetam as métricas de qualidade e os tipos de defeitos. Com base em defeitos históricos e em todos os seus dados de processo e produção relacionados, um modelo de previsão de defeitos pode ser desenvolvido para prever defeitos de qualidade futuros o mais cedo possível.

Para prever um defeito futuro, um modelo é construído usando muitos parâmetros de processo de todas as partes do laminador a quente, como forno, balança, desbaste, caixa de bobinas, esteiras de laminador, resfriamento, e bobinadeira, bem como dados de pedidos, medições de qualidade e outros pontos de dados.

Toda esta informação está ligada graças à genealogia do material e aos tempos de processo que permitem conectar informações provenientes de diferentes sistemas a um material e produto específicos. Para o conjunto de "dados de treinamento", os defeitos reais que foram detectados nas linhas de acabamento no passado também são fornecidos. Isso permite aplicar uma abordagem de Machine Learning supervisionada, como as técnicas de "Gradient Boosting over Decision Trees" [2], e de "Random Forest" [3], quando um modelo recebe explicitamente os exemplos dos eventos que ele é destinado a prever.

Diferentes tipos de defeito levarão a diferentes tratamentos de defeitos. Para distinguir qual ação executar no material suspeito, definimos um conjunto de categorias de defeitos que serão previstos independentemente. As probabilidades de defeitos são tipicamente calculadas para tipos de defeitos originados no início do



processo de produção (por exemplo, laminação a quente), mas detectados apenas em etapas posteriores do processo (por exemplo, linhas de acabamento).

A declaração exata do problema para o modelo preditivo precisa ser definida com base nas formas esperadas de como a saída do modelo (“previsão”) pode ser usada pelos sistemas automatizados de tomada de decisão existentes ou pelos operadores. Isso requer uma análise cuidadosa dos processos de negócios existentes e possíveis ações que podem ser tomadas para verificar e, se necessário, corrigir o defeito previsto.

Por exemplo, quando uma empresa deseja aplicar Machine Learning para uma tarefa de controle de qualidade, ela pode considerar a seguinte abordagem: o modelo pode prever a probabilidade de qualquer defeito futuro (fornecido como uma porcentagem que estima a probabilidade de defeito). Com base no limite empiricamente calculado ou capacidade conhecida para controle de qualidade, cada material com alta probabilidade de defeito pode ser enviado para controle de qualidade seletivo para decidir sobre uma ação específica, caso a caso.

Outro caso de uso pode ser considerado, por exemplo, para tratar tipos específicos de defeitos, como defeitos superficiais. Neste caso, todos os materiais “suspeitos” com alta probabilidade de defeitos superficiais podem ser automaticamente redirecionados para a “melhor” rota que é conhecida por tratar uma grande parte do defeito de superfície (por exemplo, incluir uma linha de decapagem que opera em uma determinada velocidade). A escolha de ações ótimas está sujeita a prioridades comerciais específicas e deve ser definida em conjunto com especialistas em processos.

Para o caso de uso em consideração, previmos primeiro se um material terá um defeito originado no laminador de tiras a quente em qualquer ponto durante as etapas de produção futuras e atribuída uma probabilidade única para cada material que sai deste laminador. Posteriormente modificamos a declaração do problema para investigar se podemos prever um ponto específico quando o defeito pode ser revelado no futuro (por exemplo, na decapagem ou no skin pass). Além disso, expandimos o conjunto de “dados de treinamento” para incluir informações mais detalhadas sobre as linhas de processamento posteriores (downstream) para poder prever defeitos “por rota” - como tal, prever se um material terá um defeito originado no laminador de tiras a quente para uma dada rota de produção que inclui um conjunto de linhas específicas e seus parâmetros de processamento.

Por exemplo, poderíamos prever que um determinado material tem 70% de probabilidade de ter um defeito de superfície se estiver passando por uma "linha de decapagem 1" rápida, enquanto a probabilidade é de apenas 40% se for processada na "linha de decapagem 2" mais lenta.

As linhas de produção no modelo de dados são descritas com um conjunto de parâmetros para que o Machine Learning possa explicar as semelhanças ou diferenças entre várias linhas para um mesmo processo de produção. Espera-se que tais modelos de previsão de qualidade possam ser mais utilizados pelo sistema de planejamento existente para escolher rotas ótimas com base no fator de qualidade futuro como fonte adicional.

Definir o caso de uso correto é uma tarefa desafiadora, já que se deve levar em consideração as necessidades de negócios (“podemos usar o modelo de saída de maneira significativa?”) e a viabilidade técnica (“podemos construir um modelo de previsão confiável e robusto com os dados que temos?”). De fato, pode ser que os dados coletados não contenham as informações que se deseja modelar. Por exemplo, se os defeitos são uma ocorrência muito rara, pode ser difícil prever cada

um deles independentemente. Em vez disso, uma abordagem com previsão de propriedades específicas do material, que são medidas para cada bobina, pode ser escolhida.

O desafio da predição de “defeito por rota” está na capacidade de fornecer diversidade de rotas suficiente nos dados históricos para o modelo para poder atribuir probabilidades diferentes a rotas diferentes. Se não houver variações suficientes nas rotas que são alternativas para se fazer o mesmo produto, uma vez que algumas das rotas nunca foram selecionadas no passado, a amostra não será totalmente representativa.

Por exemplo, muitas empresas definem uma forte preferência de rotas para certos produtos por razões comerciais (lead time, custos, etc), de modo que certos produtos são frequentemente enviados apenas para um número limitado de rotas que podem ser consideradas ótimas do ponto de vista comercial. Neste caso, o modelo não pode saber “o que teria acontecido” em outras rotas por onde as bobinas nunca foram processadas.

Como os modelos de Machine Learning são “empíricos” em sua natureza, eles não podem aprender com casos que raramente ou nunca acontecem. O modelo precisa de exemplos para aprender. O modelo pode apreender os padrões menos óbvios quando bobinas similares tomam rotas diferentes com resultados diferentes. Mas, para conseguir isso, tais ocorrências precisam estar representadas nos dados. Assim, é difícil se comprometer com o que será a declaração de problema ideal exata antes de criar o modelo ou, pelo menos, antes de analisar o conjunto de dados completo.

A resolução óbvia para a falta de exemplos no conjunto de dados é o fornecimento de mais dados, tanto em tamanho (período histórico) quanto em densidade (mais fontes de dados, maior granularidade).

No entanto, em alguns casos isso pode não ser suficiente, uma vez que o desafio está no “viés” existente nos dados, o que afeta sua representatividade. Por exemplo, neste caso, precisaríamos de dados mais diversos, não afetados pelos padrões existentes de escolha de rota.

Esse conjunto de dados não pode ser gerado simplesmente na produção. Nós precisaríamos enviar bobinas semelhantes para diferentes rotas de propósito. Mas isso não faz sentido do ponto de vista comercial, pois pode levar a perdas de produção no processo de “treinamento de geração de dados”.

Outra opção para melhorar o modelo é dar a capacidade de aprender as semelhanças entre diferentes materiais (descrevendo-os com um conjunto comparável de parâmetros) e rotas diferentes (descrevendo as linhas de maneira semelhante). Neste caso, o modelo não trataria cada rota (sequência da linha de processamento) como uma entidade única, mas poderia atribuir probabilidades para diferentes rotas com base em parâmetros conhecidos das linhas e características de processamento comparáveis (por exemplo, velocidade de decapagem). Essa é a abordagem considerada mais promissora para o caso de uso descrito.

## 2.4 Predição de Qualidade

Em tal projeto de qualidade preditiva, o modelo será tipicamente treinado usando pelo menos vários meses de dados de produção. A duração do conjunto de dados de treinamento pode variar, dependendo da frequência do processo e da taxa de amostragem disponível. Como regra geral, um ano de dados históricos costuma ser um bom tempo, já que também pode refletir alguns padrões sazonais.

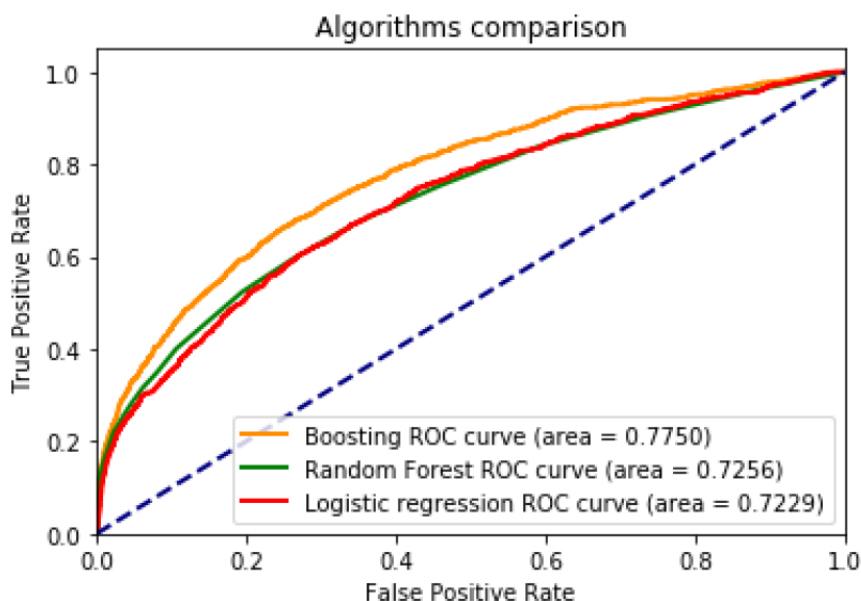
Como exemplo, o modelo inicial pode ser treinado usando nove meses de dados de produção. Além disso, 3 meses de dados podem ser usados para validar o modelo e mais 3 meses para realizar um “teste cego” de qualidade do modelo em dados completamente novos.

Durante o processo de preparação de dados, várias técnicas são aplicadas para mesclar corretamente os dados, limpar e excluir fontes de dados potencialmente corrompidas, como aquelas com valores ausentes.

Centenas de fatores (parâmetros) podem ser usados no treinamento do modelo. Deve ser confirmado que todos os fatores usados como entrada do modelo estão disponíveis em tempo real para gerar a previsão em um dado momento (para imitar a aplicação no mundo real).

Vários algoritmos de Machine Learning (gradient boosting, random forest, logistic regression) podem ser testados para escolher o melhor desempenho para essa tarefa. Os hiperparâmetros ótimos para cada algoritmo são escolhidos usando um conjunto de dados de validação separado. O melhor modelo para o caso de uso de qualidade preditiva descrito é frequentemente obtido com o algoritmo de “gradient boosting”.

A qualidade do modelo é estimada usando a métrica ROC AUC (área sob a curva ROC) [4] que é tipicamente usada para classificação probabilística e em problemas de ranking. A principal característica dessa métrica, quando comparada a outras métricas de classificação populares (acurácia, precisão, recall, F-measure [5]), está em sua capacidade de focar na qualidade geral do ranking relativo obtido pelo modelo, em vez de avaliar a assertividade de rótulos individuais.



**Figura 2.** Curva ROC de avaliação da qualidade do modelo de previsão

O exemplo acima mostra a avaliação real de 3 algoritmos: Gradient Boosting, Random Forest e Logistic Regression, aplicados ao processo de previsão de defeitos ocultos gerados em uma linha de laminação de tiras a quente.

As curvas acima são obtidas no processo de treinamento (learning) do modelo a partir da variação de um limite de tolerância à probabilidade de surgimento de um



defeito. Ou seja, as curvas são criadas com base nas probabilidades calculadas pelos modelos e no surgimento efetivo dos defeitos.

O exemplo hipotético a seguir ilustra a maneira de se calcular os pontos da curva ROC (Receiver Operating Characteristic):

Em uma base de dados de treinamento foram avaliadas 10 bobinas e com base nos fatores identificados como possíveis causas de defeito foram calculadas as probabilidades e defeitos efetivamente encontrados

Bobina #	Probabilidade Calculada	Defeito Efetivo (S/N)
Bobina 01	0,25	Não
Bobina 02	0,47	Sim
Bobina 03	0,10	Não
Bobina 04	0,21	Sim
Bobina 05	0,23	Não
Bobina 06	0,43	Sim
Bobina 07	0,34	Sim
Bobina 08	0,15	Não
Bobina 09	0,18	Não
Bobina 10	0,24	Sim

- Threshold (Limite Tolerado) = 20%

Se presumirmos que bobinas com probabilidade igual ou superior a 20% devem ser tratadas com potencial de apresentarem defeitos, o modelo teria dado o seguinte resultado:

Algoritmo A Threshold = 20%	Probabilidade ≥ Threshold	Probabilidade < Threshold
Com Defeito Real	5	0
Sem Defeito Real	2	3

Na tabela acima temos 4 valores que podem ser descritos da seguinte maneira:

- 1) Positivo verdadeiro = 5
- 2) Falso positivo = 2
- 3) Negativo verdadeiro = 3
- 4) Falso negativo = 0

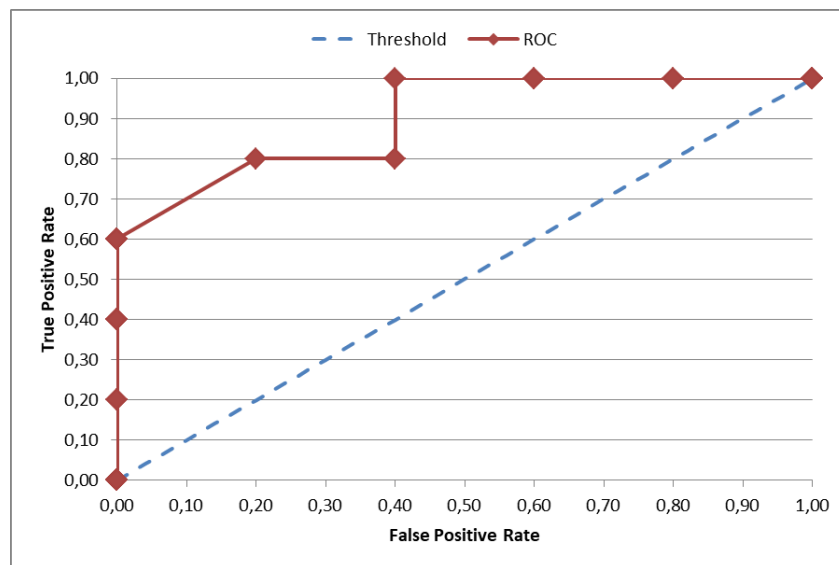
Índice de positivo verdadeiro (True Positive Rate ou Sensitivity)

$$\text{Sensitivity} = \frac{\text{Positivo Verdadeiro}}{\text{Positivo Verdadeiro} + \text{Falso Negativo}} = \frac{5}{5 + 0} = 100\%$$

Índice de falsos positivos (False Positive Rate ou '1-Specificity')

$$1 - \text{Specificity} = \frac{\text{Falsos Positivos}}{\text{Falso Positivo} + \text{Negativo Verdadeiro}} = \frac{2}{2 + 3} = 40\%$$

Então para cada valor de threshold, variando de 0 a 100 podemos calcular esses 2 índices e montar a curva gerada pelo modelo. No exemplo abaixo usamos a precisão de 2 pontos percentuais para simplificar:



Um projeto de Machine Learning é um processo iterativo, pois a primeira versão ajudará a identificar o que poderia ser melhorado. Em particular, fontes de dados adicionais a serem consideradas para o desenvolvimento do modelo são identificadas, incluindo como exemplos o desgaste de equipamento, histórico de manutenção, consumo de lubrificantes de cilindro, dados ambientais, dados de turno ou alguns níveis de agregação diferentes para registros de processo (taxa de amostragem mais alta).

## 2.4 Tratamento de defeitos previstos

O modelo preditivo de Machine Learning retorna probabilidades de uma peça apresentar um defeito.

Para traduzir essa probabilidade de defeito em uma decisão booleana de se executar uma determinada ação ou não, precisamos definir um limite. Nessa abordagem, qualquer probabilidade de defeito maior que o limite definido resultará em um conjunto de ações de tratamento de defeitos sobre o material suspeito.

A escolha do valor limite depende das ações que serão executadas no material se ele tiver uma alta probabilidade de defeito. Assim, é a parte do componente de decisão e deve ser definida como parte de um design de solução. Este valor limite dependerá principalmente de 3 fatores:

- O custo do defeito (perda calculada)
- O custo da ação (por exemplo, custo do controle de qualidade seletivo ou processamento adicional)
- A qualidade do modelo (por exemplo, qualidade da calibração do modelo)

O valor limite também deve considerar outras limitações comerciais e técnicas. De fato, não é ideal processar todos os materiais na mesma linha de decapagem. Da mesma forma, não é conveniente ter uma inspeção manual para todas as bobinas. Assim, a escolha do limite deve levar em conta a capacidade máxima de bobinas

que podem ser manuseadas por uma determinada ação, mesmo que essa ação não tenha um custo alto.

Essa abordagem permite estimar o desempenho do modelo do ponto de vista de negócios. Métricas convencionais, como a “acurácia” do modelo, têm menor aplicabilidade nesse caso. Por exemplo, pode-se alcançar uma alta taxa de acerto simplesmente prevendo-se que nenhuma bobina terá um defeito. Mas se o objetivo é identificar eventos raros que geram grandes perdas, muitas vezes é economicamente melhor ter menor precisão de acerto e tratar alguns “falsos positivos”. O raciocínio econômico deve respaldar tal interpretação. Ao equilibrar o custo da ação e o custo do defeito, podemos definir o limite ideal que seria justificado do ponto de vista do negócio.

## 2.5 Predição Integrada e Adaptativa

Tal modelo preditivo deve ser integrado para receber de forma automatizada os dados de entrada em tempo real para gerar uma previsão sobre o defeito esperado para uma dada bobina quase em tempo real. Ele também deve ser integrado à lógica de tratamento de defeitos para executar uma ação com base na previsão, a fim de reduzir a duração da ocorrência do problema até a ação.

O Machine Learning tem a vantagem de que o modelo de previsão pode ser adaptável às condições de produção em evolução. O modelo de previsão pode ser regularmente treinado com dados recentes sem qualquer intervenção especializada importante para explicar as mudanças no processo.

## 3 CONCLUSÃO

O Machine Learning apresenta uma abordagem promissora para complementar o controle de processo existente e a tomada de decisões operacionais. Nossa experiência demonstrou a capacidade do Machine Learning em prever defeitos ocultos que atualmente são totalmente despercebidos na saída de um laminador de tiras a quente, com base nos dados do processo.

Também foi explorado e confirmado que para implementar corretamente o modelo de Machine Learning, não apenas a declaração do problema deve ser escolhida corretamente, mas também o design do modelo de dados e a lógica de processamento de negócios a ser aplicada para manuseio de defeitos devem ser cuidadosamente definidos.

## REFERÊNCIAS

- 1 M. Sadiku, Y. Wang, S. Cui and S. Musa, "Industrial internet of things," International Journal of Advances in Scientific Research and Engineering, vol. 3, 2017.
- 2 T. Chen and C. Guestrin, "XGBoost: A Scalable Tree Boosting System," KDD '16, pp. 13-17, August 2016.
- 3 P. Probst, M. Wright and A.-L. Boulesteix, "Hyperparameters and Tuning Strategies for Random Forest," WIREs Data Mining Knowl Discov, 2019.
- 4 S. Narkhede, "Understanding AUC - ROC Curve," 26 June 2018. [Online]. Available: <https://towardsdatascience.com/understanding-auc-roc-curve-68b2303cc9c5>
- 5 M. Sokolova, N. Japkowicz and S. Szpakowicz, "Beyond Accuracy, F-Score and ROC: A Family of Discriminant Measures for Performance Evaluation," AI 2006: Advances in Artificial Intelligence, pp. 1015-1021, 2006.