

Diagnóstico de Proposta (EXEMPLO DEMONSTRATIVO 1)

tneemo · <https://tneemo.com> · contato@tneemo.com **Formato:** Diagnóstico R\$290 · **Editais de referência:** PIPE-FAPESP Fase 1 / PIPE Jornada (critérios da seção 8.5 de <https://fapesp.br/pipe/jornada-futuro-2026>) **Material analisado:** somente o **resumo público** do projeto "Desenvolvimento de Modelo de Machine Learning e Deep Learning para Predição da Qualidade de Painéis de Madeira MDF e MDP...", processo FAPESP 24/10924-0, empresa Futago Tecnologia Ltda., vigência de 01/09/2025 a 31/05/2026. Fonte: <https://bv.fapesp.br/pt/auxilios/118992/desenvolvimento-de-modelo-de-machine-learning-e-deep-learning-para-predicao-da-qualidade-de-paineis/>

Avisos importantes 1. Este projeto **foi aprovado** pela FAPESP. Este documento **não** julga o mérito do projeto nem da empresa. Usamos o resumo público só para demonstrar o método, analisando o texto como se fosse a seção "Resumo" de uma proposta nova. 2. A proposta completa não é pública. Por isso os componentes b, d, e, f **não podem ser avaliados** a partir do resumo. 3. As notas são **estimativas internas do ATLAS** (escala de 1 a 5). O PIPE não publica notas nem pesos. **Não há garantia de aprovação.** 4. Não temos vínculo com a FAPESP nem com a empresa citada.

1. Nota estimada por componente oficial

Componente (seção 8.5)	Nota ATLAS	Leitura
a) Projeto de Pesquisa para Inovação	2,5	O tema é relevante, mas o resumo não declara objetivo mensurável, desafio técnico, dados, método nem critério de sucesso
b) Experiência da equipe	n/a	Fora do resumo
c) Potencial mercadológico	2,5	Benefícios genéricos; o resumo não diz quem compra, quanto custa o problema nem como será comercializado
d) Bolsas PE/TT	n/a	Fora do resumo
e) Orçamento	n/a	Fora do resumo
f) Condições na empresa	n/a	Fora do resumo; não fica claro se há acesso a dados de uma fábrica parceira
Média ATLAS dos componentes avaliáveis	2,5 / 5	Escala interna; não é nota oficial

2. As 10 fragilidades principais (com trecho citado)

1. **[a.1] Não há objetivo mensurável.** Trecho: *"O conceito de 'Qualidade Preditiva' abrange diversas aplicações cruciais, como a descrição detalhada das variáveis de processo..., a previsão da qualidade... e a otimização automatizada de hiper parâmetros".* São três frentes listadas sem dizer qual será entregue nem com que métrica (erro máximo, R^2 , antecedência da previsão).
2. **[a.4] Desafio tecnológico pouco explícito frente ao estado da arte.** Trecho: *"A aplicação de ML na manufatura enfrenta desafios significativos, incluindo a adaptação a um ambiente dinâmico sujeito a incertezas".* O desafio é apresentado como algo geral da área, não como o problema específico deste projeto. A chamada exige um "problema

técnico-científico central que ainda não possui solução adequada no estado da arte" (seção 12).

3. **[a, exclusões] Risco de parecer reaplicação de técnica conhecida.** Trecho: "*é possível treinar modelos preditivos com base em dados laboratoriais*". O resumo não diz o que é novo em relação a soft sensors e modelos de regressão já usados na indústria. O parecerista pode ler isso como "mera reaplicação de conceitos" (seção 8.5.a).
4. **[a.3] Metodologia ausente no resumo.** Trecho: "*modelos estatísticos e de regressão, e a otimização automatizada de hiper parâmetros*". Não informa a base de dados (volume, período, origem), as variáveis-alvo (por exemplo, densidade, tração perpendicular, inchamento) nem o protocolo de validação.
5. **[a.2/a.5] Falta critério de sucesso da Fase 1.** O resumo inteiro não diz o que comprovará a viabilidade em 9 meses. A Fase 1 serve para isso (normas do PIPE).
6. **[c.1] Cliente não identificado.** Trecho: "*Em ambientes complexos de produção, a precisão nos processos produtivos é fundamental*". O resumo não diz quem sofre (fabricantes de MDF/MDP? qual porte? quantas plantas no Brasil?).
7. **[c.2] Dor sem número.** Trecho: "*reduzindo desperdícios e otimizando o uso de recursos*". Não quantifica a perda atual (refugo, retrabalho, tempo de laboratório) que justificaria a compra.
8. **[c.3] Rota de comercialização ausente.** Trecho: "*posiciona as indústrias para enfrentar os desafios futuros com maior agilidade*". Não diz se o produto será software, licença ou serviço, nem o primeiro cliente-piloto.
9. **[a.1] Linguagem promocional ocupa espaço técnico.** Trecho: "*impulsionando a inovação e a competitividade no mercado global de manufatura*". São frases de impacto genéricas no espaço em que o parecerista procura hipótese e método.
10. **[f.1] Acesso aos dados não demonstrado.** Trecho: "*com base em dados laboratoriais*". O resumo não diz se a empresa já tem acesso a dados de linha e de laboratório, de qual fábrica e em que condições. Esse é o principal risco de execução de um projeto de ML industrial.

3. Duas seções reescritas (modelo; os campos [entre colchetes] devem ser preenchidos pela empresa e NÃO foram inventados)

3.1 Resumo, versão reescrita

A Futago propõe verificar a viabilidade técnico-científica de um modelo de *machine learning* que prevê, **em até [X] minutos após a prensagem**, as propriedades críticas de painéis MDF e MDP: [densidade, tração perpendicular e inchamento em 24h]. A previsão usa os parâmetros da linha de produção e as características físico-químicas das matérias-primas. Hoje essas propriedades só são conhecidas após ensaios laboratoriais que levam [Y horas]. Nesse intervalo, lotes fora de especificação continuam sendo produzidos. O **desafio tecnológico** é obter previsões confiáveis sob a **deriva de processo** causada pela variabilidade da madeira e pelas trocas de produto, condição em que os modelos estáticos descritos na literatura [ref.] perdem desempenho. Na Fase 1, com [N] meses de dados históricos da planta parceira [nome/carta de anuência], vamos comparar modelos de regressão, *gradient boosting* e redes profundas, com validação temporal. O **critério de viabilidade** é atingir erro médio absoluto $\leq [Z]\%$ nas propriedades-alvo em dados de um período não usado no treino. O resultado orienta um produto de software para fabricantes de painéis, com o primeiro piloto previsto na planta parceira.

3.2 Desafio tecnológico e estado da arte, versão reescrita

Problema central: prever propriedades mecânicas de painéis em tempo próximo do real, com erro aceitável para a decisão de qualidade, em um processo **não estacionário** (variação de espécie, umidade e granulometria da madeira, trocas de espessura e de produto). **O que a literatura já resolve:** modelos de regressão e redes neurais treinados com dados de uma única condição de operação [refs.]. **O que permanece em aberto e motiva o projeto:** (i) desempenho sob deriva entre campanhas de produção; (ii) quantificação da incerteza da previsão, necessária para que o operador confie no alerta; (iii) explicabilidade das variáveis que mais influenciam cada propriedade. **Hipóteses testáveis na Fase 1:** H1. Um modelo com re-treino incremental mantém o erro $\leq [Z]\%$ ao longo de $[K]$ campanhas. H2. Os intervalos de previsão calibrados cobrem $\geq 90\%$ dos valores laboratoriais. **Por que não é reaplicação:** o projeto não implanta uma ferramenta pronta. Ele testa se é possível manter previsões confiáveis sob as condições reais de deriva da linha, o que não está demonstrado para [este tipo de processo/painel] [ref.].

4. Limites deste diagnóstico

Esta análise cobre só o resumo público. Notas estimadas. Nenhuma garantia de aprovação. As referências marcadas [ref.] precisam ser incluídas pelo proponente.