



UNIVERSIDADE FEDERAL DE PERNAMBUCO
CENTRO DE TECNOLOGIA E GEOCIÊNCIAS
DEPARTAMENTO DE ENGENHARIA MECÂNICA
CURSO DE GRADUAÇÃO EM ENGENHARIA MECÂNICA

GABRIEL LUCAS DA SILVA SANTOS

**ESTUDO REDUÇÃO DOS CUSTOS DE PENALIDADES ASSOCIADAS AO
CONSUMO DE GÁS NATURAL EM FORNOS DE WAFER EM UMA INDÚSTRIA
ALIMENTÍCIA COM O AUXÍLIO DO MÉTODO PDCA**

Recife
2025

GABRIEL LUCAS DA SILVA SANTOS

**ESTUDO REDUÇÃO DOS CUSTOS DE PENALIDADES ASSOCIADAS AO
CONSUMO DE GÁS NATURAL EM FORNOS DE WAFER EM UMA INDÚSTRIA
ALIMENTÍCIA COM O AUXÍLIO DO MÉTODO PDCA**

Trabalho de Conclusão de Curso apresentado ao Curso de Graduação em Engenharia Mecânica da Universidade Federal de Pernambuco, como requisito parcial para a obtenção do grau de Bacharel em Engenharia Mecânica.

Orientador: Prof. Antonio Marques da Costa Soares Junior

Recife

2025

Ficha de identificação da obra elaborada pelo autor,
através do programa de geração automática do SIB/UFPE

Santos, Gabriel Lucas da Silva.

Estudo redução dos custos de penalidades associadas ao consumo de gás natural em fornos de wafer em uma indústria alimentícia com o auxílio do método PDCA / Gabriel Lucas da Silva Santos. - Recife, 2025.

42 : il., tab.

Orientador(a): Antonio Marques da Costa Soares Junior

Trabalho de Conclusão de Curso (Graduação) - Universidade Federal de Pernambuco, Centro de Tecnologia e Geociências, Engenharia Mecânica - Bacharelado, 2025.

Inclui referências.

1. Gás Natural. 2. PDCA. 3. Eficiência Energética. 4. Penalidades. 5. Ferramentas da Qualidade. 6. Indústria Alimentícia. Regressão Polinomial. I. Soares Junior, Antonio Marques da Costa. (Orientação). II. Título.

620 CDD (22.ed.)



Universidade Federal de Pernambuco
Departamento de Engenharia Mecânica Centro de
Tecnologia e Geociências- CTG/EEP



ATA DE SESSÃO DE DEFESA DE
TRABALHO DE CONCLUSÃO DE CURSO – TCC2

Ao 13º dia do mês de agosto do ano de dois mil e vinte e cinco, às 10:00 horas, reuniu-se a banca examinadora para a sessão pública de defesa do Trabalho de Conclusão de Curso em Engenharia Mecânica da Universidade Federal de Pernambuco, intitulado **ESTUDO REDUÇÃO DOS CUSTOS DE PENALIDADES ASSOCIADAS AO CONSUMO DE GÁS NATURAL EM FORNOS DE WAFER EM UMA INDÚSTRIA ALIMENTÍCIA COM O AUXÍLIO DO MÉTODO PDCA**, elaborado pelo aluno **GABRIEL LUCAS DA SILVA SANTOS**, matrícula 20190035504, sob a orientação do Prof. **Antonio Marques da Costa Soares Junior**. A banca foi composta pelos avaliadores: Prof. **Antonio Marques da Costa Soares Junior** (orientador), Profa. **Marcele Elisa Fontana** (avaliadora) e Prof. **Augusto José da Silva Rodrigues** (avaliador). Após a exposição oral do trabalho, o candidato foi arguido pelos componentes da banca que em seguida reuniram-se e deliberaram pela sua Aprovado, atribuindo-lhe a média 7,7, julgando-o apto(x) / inapto() à conclusão do curso de Engenharia Mecânica. Para constar, redigi a presente ata aprovada por todos os presentes, que vai assinada pelos membros da banca.

Orientador: Prof. Antonio Marques da Costa Soares Junior Nota: 8,0

Assinatura

Avaliadora: Profa. Marcela Elisa Fontana Nota: 7,0
Interna

Assinatura

Avaliador: Prof. Augusto José da Silva Rodrigues Nota: 8,0
Externo

Assinatura

Recife, 13 de agosto de 2025.

Prof. Marcus Costa de Araújo
Coordenador de Trabalho de Conclusão de curso - TCC
Curso de Graduação em Engenharia Mecânica – CTG/EEP-UFPE

AGRADECIMENTOS

Agradeço a Deus, fonte de sabedoria, por Seu amor e misericórdia que me sustentaram. A Nossa Senhora, pela intercessão e proteção. Sem a presença divina, este sonho não teria se concretizado.

À minha família — meus pais Maria Gorette da Silva Santos e Severino Francisco dos Santos Filho, minha irmã Lourdes Gabrielly, minhas avós Carmelita Gomes e Maria de Lourdes, meu avô Severino Ramos e, com saudade, meu avô Severino Francisco dos Santos — pelo amor, apoio e por serem minha base. Aos meus pais, que me proporcionaram uma educação de qualidade, mesmo com dificuldades. À minha avó Carmelita, que sempre me acolheu com amor e ajudou meus pais. Ao meu avô Severino Francisco, que me ensinou o valor do cuidado, da responsabilidade e do amor familiar.

À minha noiva, Aline Lira, que foi minha companheira, incentivadora e apoio incondicional. Sua presença me deu forças e motivação nos momentos desafiadores. Este trabalho também é seu, pois sem o seu apoio incondicional, a jornada teria sido muito mais difícil.

Aos amigos da universidade — Antonio Matheus, Arthur Oliveira, Augusto Santos, Delmario Siqueira, Guskarllos Oliveira, Heitor Santana, Kendysson Paulo, Lucas Aguiar, Lucas Diego, Lucas Matheus, Lucas Rafael, Mateus Duarte, Paulo Rogerio, Pedro Augusto, Vinicius Lima, Vinicius Nunes e Welison Alves — pela parceria nos estudos, risadas e amizade verdadeira. Em especial, ao João Victor Siqueira, que foi mais que um amigo: um irmão.

Aos colegas de trabalho durante o estágio — Adriana Nascimento, Caio Falcão, Darlan Henrique, Dweudes Junior, José Gonçalves Junior, Leandro Andrade, Liliane Custódio e Rogério Aparecido — pela colaboração e crescimento profissional. Aos amigos e companheiros de estágio — Bárbara Costa, Cleiton Paulo, Edlayne Santos, Larissa Prado, Lucas Carneiro, Maíra Gomes e Maria Victoria — pela amizade e cumplicidade que tornaram o ambiente de aprendizado mais leve.

Ao meu professor de matemática do ensino médio, Luiz Manoel Santana, pelo incentivo e dedicação durante o vestibular, à Universidade Federal de Pernambuco e aos professores da graduação, pelo suporte e contribuição para minha formação.

Este trabalho é fruto de anos de esforço e perseverança. Enfrentei longas viagens diárias, cansaço e desafios, mas cada passo foi sustentado pela fé e determinação. A todos, minha eterna gratidão. Cada página carrega meu empenho, amor, apoio e fé. A Deus, toda a honra e glória.

“A esperança tem duas filhas lindas: a indignação
e a coragem. A indignação nos ensina a não aceitar
as coisas como estão; a coragem, a mudá-las.”
— Santo Agostinho

RESUMO

A busca por eficiência energética e controle de custos operacionais tem se intensificado na indústria brasileira, especialmente em setores com alto consumo de insumos energéticos, como o alimentício. Este trabalho teve como objetivo reduzir os custos com penalidades contratuais decorrentes do consumo excessivo ou insuficiente de gás natural em fornos de wafer, por meio da aplicação do ciclo PDCA e de ferramentas estatísticas da qualidade. O estudo foi conduzido em uma planta industrial real e partiu da necessidade de garantir que o consumo diário de gás natural se mantivesse dentro da faixa contratual estabelecida, evitando penalidades significativas. A metodologia adotada foi baseada em uma abordagem focada na identificação, análise e correção das falhas no planejamento do consumo energético. Na fase de planejamento (*Plan*), foi realizada uma coleta e análise dos dados históricos de produção e consumo de gás natural de maneira estratificada. Utilizando o software Minitab, foram construídos histogramas para identificar a distribuição do consumo, seguidos de gráficos de dispersão e regressões lineares e polinomiais de segundo grau, que modelaram a relação entre o volume de produção e o consumo energético. Na etapa de execução (*Do*), com base nas equações geradas, foi desenvolvido um modelo preditivo de consumo que passou a orientar a rotina da operação. Durante a fase de verificação (*Check*), os resultados foram novamente avaliados através de ferramentas estatísticas, que confirmaram a eficácia do modelo. Houve estabilização do padrão de consumo, aumento da aderência às faixas contratuais e significativa redução nas penalidades. Com o uso efetivo das equações polinomiais, observou-se uma queda contínua dos custos com multas, que acumulou aproximadamente 80% de redução. Na fase final do PDCA (*Act*), as boas práticas foram padronizadas, e o modelo de gestão passou a integrar os procedimentos operacionais com acompanhamento sistemático. A metodologia aplicada demonstrou ser eficaz não apenas na economia financeira, mas também na construção de uma cultura de controle operacional e melhoria contínua. O projeto contribui ainda para os Objetivos de Desenvolvimento Sustentável (ODS), promovendo consumo responsável (ODS 12) e inovação industrial (ODS 9).

Palavras-chave: Gás Natural. PDCA. Eficiência Energética. Penalidades. Ferramentas da Qualidade. Indústria Alimentícia. Regressão Polinomial.

LISTA DE FIGURAS

Figura 1	Ciclo PDCA	17
Figura 2	Histograma simétrico ou normal	20
Figura 3	Histograma assimétrico	20
Figura 4	Histograma com dois picos	21
Figura 5	Histograma em platô	21
Figura 6	Histograma aleatório	21
Figura 7	Gráfico de dispersão: Correlações	22
Figura 8	Gráfico de dispersão: Forte e fraca	23
Figura 9	Fluxograma da aplicação do PDCA	25
Figura 10	Histograma de consumo de gás (m ³) para dias úteis	29
Figura 11	Histograma de volume (ton) para dias úteis	29
Figura 12	Histograma de consumo de gás (m ³) para sábados	30
Figura 13	Histograma de volume (ton) para sábados	30
Figura 14	Histograma de consumo de gás (m ³) para domingos	31
Figura 15	Histograma de volume (ton) para domingos	31
Figura 16	Gráfico de regressão linear para dias úteis: Volume <i>versus</i> Consumo	32
Figura 17	Gráfico de regressão linear para sábados: Volume <i>versus</i> Consumo	33
Figura 18	Gráfico de regressão linear para domingos: Volume <i>versus</i> Consumo	33
Figura 19	Gráfico de regressão polinomial para dias úteis: Volume <i>versus</i> Consumo..	35
Figura 20	Gráfico de regressão polinomial para sábados: Volume <i>versus</i> Consumo	35
Figura 21	Gráfico de regressão polinomial para domingos: Volume <i>versus</i> Consumo..	36
Figura 22	Custo com penalidades ao longo dos meses	36

LISTA DE TABELAS

Tabela 1	Valores de R^2 obtidos na regressão polinomial de primeiro grau	32
Tabela 2	Valores de R^2 obtidos na regressão polinomial de segundo grau	34

SUMÁRIO

1	INTRODUÇÃO	9
1.1	Objetivos	10
1.1.1	<i>Objetivo Geral</i>	10
1.1.2	<i>Objetivos Específicos</i>	10
1.2	Justificativas	10
2	FUNDAMENTAÇÃO TEÓRICA	12
2.1	Consumo de Gás Natural em Processos Industriais	12
2.1.1	<i>Importância do Gás Natural</i>	12
2.1.2	<i>Desafios na Programação do Consumo de Gás</i>	13
2.1.3	<i>Benefícios da Melhoria do Consumo de Gás</i>	14
2.2	Gestão da Qualidade	15
2.3	Ciclo PDCA	17
2.4	Ferramentas da Qualidade	18
2.4.1	<i>Histograma</i>	19
2.4.2	<i>Gráfico de Dispersão</i>	22
2.5	Modelagem Estatística Preditiva	23
3	METODOLOGIA	26
3.1	Caracterização da Pesquisa	26
3.2	Aplicação do PDCA	27
4	RESULTADOS	29
4.1	Planejar (<i>Plan</i>)	29
4.2	Executar (<i>Do</i>)	33
4.3	Verificar (<i>Check</i>)	34
4.4	Agir (<i>Act</i>)	37
5	CONCLUSÃO	38
5.1	Contribuições	39
	REFERÊNCIAS	40

1 INTRODUÇÃO

A crescente competitividade no mercado industrial tem incentivado as empresas a buscarem constantemente a otimização de seus processos e produtos. O objetivo não é apenas atender, mas também exceder as expectativas dos clientes, oferecendo qualidade a preços competitivos e assegurando a sustentabilidade a longo prazo (DE FEO, 2019).

Para alcançar tais resultados, é necessário que diferentes fatores organizacionais estejam alinhados. Estratégias definidas pela alta administração deve ser traduzidas em práticas eficazes no chão de fábrica, de forma que cada nível contribua para o desempenho global da empresa (ANTUNES; ARANTES, 2022).

Uma das formas mais eficazes de garantir esse alinhamento é o uso de metodologias de melhoria contínua, que permitem analisar dados, identificar causas de problemas e implementar soluções de maneira estruturada e lógica, promovendo ganhos consistentes (HASHMI, 2010).

No setor alimentício, destaca-se o desafio da gestão do consumo de gás natural em fornos de wafer. Falhas na programação diária podem gerar penalidades contratuais significativas, aumentando os custos operacionais e comprometendo a competitividade. Para evitar tais penalidades, o contrato estabelece que o consumo diário de gás deve se manter dentro de uma margem de +5% e -10% do volume contratado.

Este estudo busca enfrentar essa problemática por meio da aplicação do método PDCA e de ferramentas da qualidade associadas. A escolha do PDCA se justifica por sua simplicidade, aplicabilidade em diferentes níveis organizacionais e por favorecer a melhoria contínua. Além disso, integra-se de forma eficiente a ferramentas estatísticas, permitindo maior confiabilidade nas análises e nas tomadas de decisão.

Assim, o objetivo deste trabalho é desenvolver uma abordagem que proporcione maior previsibilidade do consumo de gás natural, reduzindo os custos decorrentes de falhas de programação e contribuindo para a eficiência operacional e a sustentabilidade financeira da empresa.

1.1 Objetivos

1.1.1 Objetivo Geral

Reduzir os custos de penalidades por consumo excessivo ou insuficiente de gás natural em fornos de wafer em uma indústria alimentícia, por meio da aplicação da metodologia PDCA, tendo como premissa a melhoria do planejamento e do monitoramento do consumo de gás visando ao aumento da precisão e da previsibilidade na programação do uso energético.

1.1.2 Objetivos Específicos

- Coletar e analisar dados de consumo de gás natural, a fim de compreender a dinâmica e as variabilidades no uso energético;
- Identificar padrões e desvios no consumo de gás natural, utilizando ferramentas de qualidade para destacar as principais causas de ineficiência;
- Implementar melhorias no processo de programação do consumo de gás, visando à otimização da precisão e redução de custos associados às penalidades financeiras.

1.2. Justificativas

A eficiência na gestão de recursos energéticos, especialmente o gás natural, constitui um dos principais desafios enfrentados pelas indústrias alimentícias. A programação inadequada do consumo de gás pode resultar em penalidades severas impostas pelos fornecedores, elevando significativamente os custos operacionais e impactando diretamente a competitividade da empresa. Qualquer desvio além da faixa estipulada resulta em penalidades financeiras substanciais (COSTA, 2019).

No caso da empresa estudada, verificou-se que falhas recorrentes na programação do consumo de gás natural vinham ocasionando penalidades financeiras expressivas, que representavam um impacto considerável no orçamento da área de utilidades. A ausência de ferramentas analíticas estruturadas dificultava a previsibilidade do consumo, aumentando a probabilidade de ultrapassar os limites contratuais definidos com a fornecedora. Essa situação despertou a necessidade de desenvolver um método sistemático capaz de proporcionar maior controle e confiabilidade no planejamento do consumo.

Dessa forma, este estudo justifica-se pela necessidade de aplicar métodos eficazes para prever e controlar o consumo de gás natural, minimizando as penalidades e, conseqüentemente, os custos operacionais. Ferramentas da qualidade, como histogramas, gráficos de dispersão e

linhas de tendência, oferecem uma abordagem sistemática para analisar dados de consumo, identificar padrões e implementar melhorias no processo de programação (FROST, 2019; GURUS, 2021; NEYESTANI, 2017).

A aplicação dessas ferramentas, estruturada no ciclo PDCA, é fundamental para a melhoria contínua, conceito central na gestão da qualidade voltado à otimização dos processos industriais (BHUIYAN; BAGHEL, 2005; HASHMI, 2010).

Além do impacto financeiro, uma programação precisa do consumo de gás contribui também para a sustentabilidade ambiental da empresa, otimizando o uso de um recurso energético vital e alinhando-se às exigências regulatórias e às boas práticas de eficiência energética.

2 FUNDAMENTAÇÃO TEÓRICA

2.1 Consumo de Gás Natural em Processos Industriais

2.1.1 Importância do Gás Natural

O gás natural desempenha um papel cada vez mais relevante na matriz energética industrial do Brasil, refletindo tanto as tendências globais quanto as peculiaridades locais de consumo. No cenário internacional, o gás natural tem sido uma escolha preferencial para diversos setores industriais devido à sua elevada eficiência energética e ao menor impacto ambiental, quando comparado a outros combustíveis fósseis, como o carvão e o óleo combustível. No Brasil, essa preferência tem impulsionado uma demanda crescente, especialmente por setores industriais que enxergam no gás natural uma alternativa viável para otimizar seus processos e reduzir custos operacionais (BHUIYAN; BAGHEL, 2005).

A demanda global por gás natural aumentou significativamente nas últimas décadas. Países como os Estados Unidos lideraram essa transição para fontes energéticas mais limpas, impulsionados pela expansão da produção de gás de xisto (*shale gas*), notadamente a partir de 2010. Esse cenário contribuiu para consolidar o gás natural como uma das principais fontes de energia na América do Norte, resultando em uma expressiva redução nas emissões de gases de efeito estufa e favorecendo uma maior integração energética regional (EPE, 2020). No Brasil, essa tendência internacional impacta diretamente o mercado interno, estimulando a modernização e a expansão da infraestrutura energética nacional.

No contexto interno, o setor industrial brasileiro é o maior consumidor de gás natural, representando uma parcela expressiva da demanda nacional. Esse consumo é diversificado, abrangendo desde o uso como insumo térmico em processos de alta intensidade até sua aplicação como matéria-prima em processos químicos. Conforme apontado pela Empresa de Pesquisa Energética (EPE, 2020), setores como o químico, siderúrgico, cerâmico, e de papel e celulose destacam-se como os principais demandantes. A constância e confiabilidade energética exigidas por esses setores tornam o gás natural uma escolha estratégica para o abastecimento de caldeiras, fornos e outros equipamentos críticos (CAMPOS, 2013).

A distribuição do consumo de gás natural no país está diretamente associada ao nível de desenvolvimento da infraestrutura de transporte e distribuição. Estados como São Paulo e Rio de Janeiro, que contam com redes de gasodutos mais consolidadas, concentram a maior parte do consumo industrial. Nessas regiões, o gás natural é essencial para processos produtivos

contínuos e para garantir elevada confiabilidade energética. Por outro lado, em regiões com infraestrutura limitada, o crescimento do consumo ainda enfrenta barreiras, fazendo com que muitas indústrias dependam de fontes menos eficientes e mais poluentes.

Para expandir o acesso ao gás natural e fortalecer seu papel estratégico, é fundamental o investimento em infraestrutura. Iniciativas como a construção de rotas de escoamento offshore, a implantação de terminais de regaseificação de GNL e a ampliação da malha de gasodutos são consideradas cruciais para viabilizar o atendimento a regiões industriais em crescimento. O programa “Novo Mercado de Gás”, que tem como objetivo promover a concorrência e reduzir os custos do insumo, também é peça-chave nesse processo. Espera-se que, com o incentivo à abertura de mercado e à entrada de novos agentes, o gás natural se torne uma fonte mais acessível e competitiva em todo o país (DE FEO, 2019).

Além da questão estrutural, o Brasil enfrenta desafios relacionados ao custo e à eficiência do uso do gás natural. A eficiência energética, nesse caso, é um fator determinante para a competitividade da indústria nacional. Em segmentos como o alimentício, que exige controle preciso de temperatura e uniformidade na cocção dos produtos, o gás natural cumpre um papel essencial. Na produção de biscoitos, por exemplo, ele é amplamente utilizado no aquecimento de fornos, garantindo qualidade no processo e redução de perdas (CUSTÓDIO, 2015).

Apesar dos avanços obtidos, ainda há grande potencial para a ampliação do uso do gás natural na indústria brasileira. O desenvolvimento de tecnologias voltadas à eficiência energética, associado à expansão da infraestrutura de distribuição, tende a consolidar o gás natural como elemento central da matriz energética industrial. Segundo projeções da EPE (2020), a demanda nacional por gás natural deve crescer a uma taxa média de 5% ao ano até 2030, o que reforça sua importância como vetor para o desenvolvimento industrial sustentável.

2.1.2 Desafios na Programação do Consumo de Gás

A programação do consumo de gás natural nas indústrias representa um dos principais desafios para a manutenção da eficiência operacional e da sustentabilidade econômica. A variabilidade do consumo decorre de múltiplos fatores internos e externos que afetam a demanda de energia de forma contínua e imprevisível.

Um dos fatores mais relevantes é a demanda de produção, que pode variar em função de lotes maiores ou menores, sazonalidade de mercado e oscilações nos pedidos dos clientes. Essas flutuações impactam diretamente o volume de gás consumido, já que a queima em fornos

industriais ou sistemas térmicos acompanha a intensidade do processo produtivo (JEYARAMAN; TEO, 2010).

Outro aspecto crítico são as paradas de manutenção, programadas ou não, que reduzem temporariamente a utilização dos fornos e equipamentos consumidores de gás. A imprevisibilidade de paradas corretivas, em especial, aumenta a dificuldade em manter o consumo dentro da faixa contratada, elevando o risco de penalidades financeiras (COSTA, 2019).

As características de fornecimento e da infraestrutura de distribuição também afetam a confiabilidade do suprimento. Regiões com malha de gasodutos limitada enfrentam maior volatilidade de preços e restrições operacionais, dificultando a previsibilidade do consumo industrial (DE FEO, 2019).

Um ponto de grande relevância é o cumprimento dos contratos de fornecimento de gás, que geralmente estabelecem faixas de consumo com limites de tolerância, a exemplo de até 5% acima ou 10% abaixo da quantidade contratada. O não cumprimento dessas margens pode gerar penalidades financeiras significativas, seja por ultrapassar o teto de consumo, resultando em custos adicionais elevados, seja por consumir abaixo do piso contratado, comprometendo a rentabilidade da empresa e o equilíbrio contratual com o fornecedor. Essas penalidades existem como forma de garantir estabilidade ao sistema de distribuição e previsibilidade de demanda, mas, para a indústria, representam um fator de pressão financeira que reforça a necessidade de precisão no planejamento (COSTA, 2019).

Dessa forma, a previsão de consumo de gás natural exige modelos analíticos capazes de considerar múltiplas variáveis, como sazonalidade, oscilações de produção, pedidos de clientes, paradas de manutenção e restrições de fornecimento. A ausência de uma previsão bem estruturada compromete a eficiência energética e pode gerar tanto desperdícios quanto escassez, resultando em impactos produtivos e financeiros expressivos (MONTGOMERY; RUNGER, 2012).

2.1.3 Benefícios da Melhoria do Consumo de Gás

A melhoria do consumo de gás natural oferece benefícios expressivos para a indústria, destacando-se a redução dos custos operacionais, a elevação da eficiência energética e a mitigação dos impactos ambientais. Uma gestão energética eficaz não apenas proporciona economias diretas, mas também fortalece a competitividade empresarial ao viabilizar a produção de bens com menores custos e maior valor agregado ambiental. Ademais, o uso

otimizado do gás natural facilita o cumprimento de normas ambientais cada vez mais exigentes, reforçando o compromisso da empresa com a sustentabilidade (CAMPOS, 2013).

A adoção de metodologias de melhoria contínua e ferramentas de qualidade, como histogramas, gráficos de dispersão e análises de tendência, possibilita compreender padrões de consumo e direcionar intervenções mais precisas e eficazes. Tais práticas contribuem não apenas para o controle operacional, mas também para a redução de perdas energéticas e para a consolidação de uma cultura organizacional voltada à excelência (ANTUNES, 2022; NEYESTANI, 2017).

Além disso, a aplicação de boas práticas de gestão do consumo de gás prepara as empresas para lidar com oscilações no preço dos combustíveis e com as novas exigências regulatórias. A eficiência energética, portanto, torna-se um diferencial competitivo, agregando valor à marca e contribuindo para a perenidade dos negócios em um cenário global cada vez mais sensível às questões ambientais e sociais (PEPPER; SPEDDING, 2010).

A gestão estratégica do consumo de gás natural representa, assim, um investimento inteligente e necessário. Ao garantir uma operação mais enxuta, econômica e sustentável, a empresa amplia sua capacidade de adaptação às mudanças do mercado e reforça seu compromisso com a responsabilidade socioambiental.

2.2 Gestão da Qualidade

A gestão da qualidade é uma abordagem essencial para assegurar que produtos e serviços atendam não apenas aos padrões estabelecidos, mas também às expectativas dos clientes, sendo um elemento-chave para a competitividade e a sustentabilidade das organizações. Sua origem e evolução estão profundamente conectadas ao desenvolvimento industrial, especialmente a partir do pós-Segunda Guerra Mundial, quando o Japão, diante de um cenário econômico devastado, adotou métodos científicos de padronização da produção. Essa transformação foi influenciada por estudiosos como Frank Gilbreth e Frederick Taylor, pioneiros da administração científica, e posteriormente consolidada por especialistas como Joseph Moses Juran e William Edwards Deming, que desempenharam papéis fundamentais na disseminação da cultura de melhoria contínua (CHIAVENATO, 1983; PALADINI, 2004).

Entre os conceitos centrais da gestão da qualidade, destaca-se a filosofia da melhoria contínua, também conhecida como Kaizen. No idioma japonês, “Kai” significa mudança e “Zen” significa melhoria, formando um conceito que representa o aprimoramento constante e sistemático dos processos. Essa filosofia promove não apenas ajustes técnicos, mas também

uma transformação cultural nas organizações, incentivando todos os colaboradores a participar ativamente da busca por melhorias (YENTSANG et al., 2010; CUSTODIO, 2015). Essa visão está fortemente associada à Gestão da Qualidade Total (TQM – Total Quality Management), uma prática integrada que envolve toda a organização, da alta administração ao chão de fábrica, com o objetivo de incorporar a qualidade em cada etapa da produção (GHINATO, 2000).

No cenário contemporâneo, a gestão da qualidade tornou-se uma exigência estratégica, pois permite às empresas atenderem às rigorosas regulamentações ambientais e de segurança, além de conquistar vantagem competitiva. A adoção de práticas de gestão da qualidade contribui para a redução de custos, aumento da produtividade e maior satisfação dos clientes. Ferramentas como histogramas, gráficos de dispersão, Diagramas de Pareto e Diagramas de Causa e Efeito têm papel essencial na identificação, análise e resolução de problemas, promovendo a excelência operacional e impulsionando a melhoria contínua (HASHMI, 2010; JEYARAMAN; TEO, 2010).

Contudo, a eficácia de programas de melhoria contínua e gestão da qualidade depende fortemente do envolvimento de todos os níveis organizacionais e da capacidade de adaptação frente às transformações do mercado. Como destacam (BESSANT, 1999) e (OLIVEIRA et al., 2017), a melhoria contínua exige o gerenciamento disciplinado das atividades diárias, permitindo que a empresa responda rapidamente às exigências dos consumidores e mantenha sua competitividade. Ainda que os benefícios da gestão da qualidade sejam amplamente reconhecidos — como a redução de falhas e o aumento da produtividade (COSTA, 2019) —, é necessário assegurar que os resultados obtidos sejam sustentáveis ao longo do tempo. Pesquisas adicionais são recomendadas para compreender o ciclo de vida dos programas de qualidade e garantir a perenidade das melhorias implementadas (ARANTES, 2022; NEYESTANI, 2017).

Em síntese, a gestão da qualidade é indispensável para organizações que desejam manter sua relevância e desempenho em um ambiente de negócios cada vez mais competitivo. Ao incorporar uma cultura de melhoria contínua e adotar ferramentas eficazes, as empresas fortalecem sua posição estratégica e desenvolvem maior resiliência diante das exigências do mercado (PEPPER; SPEDDING, 2010; SALAH; RAHIM; CARRETERO, 2010; SHINGO, 1996).

Para sustentar essa filosofia de gestão da qualidade e garantir a eficácia dos programas de melhoria contínua, é fundamental a aplicação de ferramentas específicas que auxiliem na análise, controle e aperfeiçoamento dos processos organizacionais. As chamadas ferramentas da qualidade permitem às empresas diagnosticar falhas, monitorar variáveis e propor soluções de forma estruturada e baseada em dados. Entre essas ferramentas, destacam-se os histogramas,


gráficos de dispersão, diagramas de Pareto, diagrama de Ishikawa, além de metodologias sistemáticas como o Ciclo PDCA, que contribuem diretamente para o desenvolvimento de ações corretivas e preventivas consistentes. Essas ferramentas serão exploradas no próximo tópico.

2.3 Ciclo PDCA

O ciclo PDCA (Plan-Do-Check-Act), amplamente difundido na gestão da qualidade, é uma ferramenta cíclica voltada para a solução de problemas e melhoria contínua de processos. Sua origem remonta aos estudos do engenheiro Walter A. Shewhart, que propôs, ainda em 1939, um modelo de produção em massa estruturado como um sistema cíclico composto por três etapas: especificação, produção e inspeção. Shewhart sugeriu que esses passos deveriam ser vistos como parte de um processo dinâmico e científico de aquisição de conhecimento, o que deu origem ao primeiro ciclo de melhoria contínua (SHEWHART, 1939; MOEN & NORMAN, 2007).

A partir dessa base, o ciclo foi difundido e aprimorado por W. Edwards Deming, que levou o modelo ao Japão na década de 1950. Lá, o conceito evoluiu para o conhecido PDCA, com quatro fases bem definidas: Planejar (Plan), Executar (Do), Verificar (Check) e Agir (Act) (ORIBE, 2009). A principal característica do PDCA é seu caráter iterativo e sistemático, permitindo o aprendizado contínuo a partir das ações realizadas e dos resultados obtidos. Cada fase do PDCA (Figura 1) possui um papel fundamental.

Figura 1 - Ciclo PDCA.



Fonte: Autor, 2025.

- Plan (Planejar): identificar um problema ou oportunidade de melhoria, analisar causas, definir metas e elaborar um plano de ação;
- Do (Executar): implementar as ações planejadas, preferencialmente em pequena escala, como forma de teste;
- Check (Verificar): monitorar os resultados obtidos, comparando-os com as metas estabelecidas;
- Act (Agir): padronizar as ações que resultaram em sucesso ou revisar o plano caso os resultados não tenham sido satisfatórios.

Com o passar dos anos, variantes do ciclo surgiram, como o PDSA (Plan-Do-Study-Act), proposto pelo próprio Deming em 1993, enfatizando a fase de estudo e aprendizado como substituta da simples verificação (DEMING, 1993). Nesse modelo, a etapa “Study” permite uma análise mais aprofundada dos resultados, o que amplia o valor gerado pelo ciclo como ferramenta de aprendizado organizacional.

Outras variações incluem o PDCL (Plan-Do-Check-Learn), promovido pela Fundação Nacional da Qualidade (FNQ), que reforça a importância do aprendizado contínuo como resultado do ciclo, além do CAPD, usado em contextos de ação corretiva, no qual o ciclo se inicia pela verificação do problema (Check), antes do planejamento das ações corretivas (ORIBE, 2009).

Mais do que um método, o PDCA pode ser compreendido como um conceito estruturante, capaz de orientar desde pequenas intervenções até estratégias organizacionais complexas. Ele serve como base para diversas metodologias modernas de gestão da qualidade, como o MASP, Six Sigma (DMAIC), ISO 9001 e o Modelo de Melhoria da API (Associates in Process Improvement), sendo considerado um verdadeiro legado da gestão científica moderna (ORIBE, 2009; MOEN & NORMAN, 2007).

2.4 Ferramentas da Qualidade

As ferramentas da qualidade surgiram como parte fundamental do movimento de gestão voltado à melhoria contínua dos processos e ao aumento da eficiência organizacional. Elas foram inicialmente difundidas no Japão no período pós-Segunda Guerra Mundial, tendo como expoentes figuras como Deming, Juran e Ishikawa, que estruturaram os pilares do Controle da Qualidade Total (CAMPOS, 2013; ARANTES, 2022).

Dentre as ferramentas clássicas destacam-se o histograma, o gráfico de dispersão, o diagrama de causa e efeito, o fluxograma, o gráfico de Pareto, a folha de verificação e o

diagrama de controle. Estas são conhecidas como as Sete Ferramentas da Qualidade, sendo amplamente utilizadas por sua simplicidade e eficácia na análise de dados e solução de problemas (NEYESTANI, 2017; PALADINI, 2004).

No contexto deste trabalho, utilizaram-se principalmente o histograma, para avaliar a distribuição e frequência dos dados de consumo de gás natural; o gráfico de dispersão, para analisar a correlação entre o volume de produção e o consumo de energia; e a regressão linear, como ferramenta de quantificação estatística das relações entre as variáveis. Essas ferramentas permitem visualizar comportamentos, identificar tendências e suportar tomadas de decisão com base em dados objetivos (FROST, 2019; GURUS, 2021).

A aplicação das ferramentas da qualidade está diretamente ligada ao conceito de melhoria contínua (Kaizen), que propõe ajustes progressivos e sistemáticos nos processos, com base em análises rigorosas de dados e evidências (CUSTODIO, 2015; BHUIYAN; BAGHEL, 2005). Além disso, a integração dessas ferramentas com metodologias como o PDCA (Plan-Do-Check-Act) e o TQM (Total Quality Management) potencializa sua eficácia e contribui para a maturidade dos sistemas de gestão da qualidade (COSTA, 2019; DEFE, 2019).


Por fim, vale destacar que a escolha da ferramenta adequada deve considerar o tipo de dado analisado, o objetivo da investigação e o nível de conhecimento da equipe envolvida. A correta aplicação dessas ferramentas constitui um diferencial na gestão operacional e estratégica das organizações (ANTUNES, 2022; CHIAVENATO, 1983).

2.4.1 Histograma

O histograma é uma ferramenta gráfica que permite a visualização da distribuição de um conjunto de dados. Ele é utilizado para identificar a frequência de ocorrência de diferentes intervalos de valores, facilitando a detecção de padrões e tendências. Segundo (FROST, 2019), o uso de histogramas é fundamental para entender a variabilidade dos processos e identificar oportunidades de melhoria. Essa ferramenta é amplamente utilizada em gestão da qualidade para monitorar e melhorar processos (NEYESTANI, 2017).


Existem diferentes tipos de histograma. O histograma simétrico ou normal (Figura 2) ocorre quando o processo está bem controlado e os dados são consistentes, permitindo apenas pequenas variações. Já o histograma assimétrico, representado na Figura 3, geralmente ocorre quando existe um limite definido que os dados não podem ultrapassar; seu pico se concentra em um dos extremos, e os dados fora do padrão decrescem para o lado oposto (FERRAMENTAS DA QUALIDADE, 2016).

Figura 2 - Histograma simétrico ou normal.



Fonte: Ferramentas da Qualidade, 2016.


Figura 3 - Histograma assimétrico.



Fonte: Ferramentas da Qualidade, 2016.


O histograma com dois picos (Figura 4) surge quando há duas coletas de dados distintas para comparação, e a análise deve ser feita separadamente, observando as características de cada gráfico. O histograma em platô, com representação na Figura 5, normalmente aparece quando há alguma anormalidade nos dados decorrente de falhas, apresentando barras praticamente do mesmo tamanho. Por fim, o histograma aleatório (Figura 6) caracteriza-se pela ausência de padrão, com as barras variando de maneira imprevisível, sem critério aparente (FERRAMENTAS DA QUALIDADE, 2016).

Figura 4 - Histograma com dois picos.




Fonte: Ferramentas da Qualidade, 2016.

Figura 5 - Histograma em platô.



Fonte: Ferramentas da Qualidade, 2016.

Figura 6 - Histograma aleatório.




Fonte: Ferramentas da Qualidade, 2016.

2.4.2 Gráfico de Dispersão

O gráfico de dispersão é uma representação visual que mostra a relação entre duas variáveis. Essa ferramenta é útil para identificar correlações e tendências que podem não ser evidentes em tabelas de dados. De acordo com (GURUS, 2021), os gráficos de dispersão ajudam a identificar possíveis causas de problemas e são essenciais para análises estatísticas mais aprofundadas. A aplicação de gráficos de dispersão é uma prática comum em estudos de melhoria contínua e controle de qualidade (HASHMI, 2010).

Existem três tipos de correlações nos gráficos de dispersão, encontrados na Figura 7. O gráfico de correlação positiva ocorre quando os pontos de tendência se aglomeram de maneira crescente. O de correlação negativa se dá com a distribuição decrescente dos dados. Já o gráfico de correlação nula ocorre quando não há tendência na distribuição dos dados (FERRAMENTAS DA QUALIDADE, 2016).


Figura 7 - Gráfico de dispersão: Correlações.



Fonte: Ferramentas da Qualidade, 2016.

Além das correlações esse tipo de gráfico também pode ser classificado como forte ou fraco, dependendo do tipo de dispersão apresentada pelos pontos. Desse modo, considera-se como forte quando a dispersão dos pontos é menor, e fraca quando os pontos estiverem mais dispersos. Ambos os gráficos estão representados na Figura 8 (FERRAMENTAS DA QUALIDADE, 2016).

Figura 8 - Gráfico de dispersão: Forte e fraca.



Fonte: Ferramentas da Qualidade, 2016.

A linha de tendência representa o comportamento de um conjunto de dados ao longo do tempo, sendo amplamente utilizada para prever valores futuros com base em dados históricos. Conforme descrito por (ANTUNES, 2022), as linhas de tendência desempenham um papel essencial na análise preditiva, pois ajudam a identificar padrões e tendências a partir de dados passados, facilitando a compreensão do comportamento de variáveis ao longo do tempo e permitindo a antecipação de possíveis cenários futuros. Dessa forma, as linhas de tendência são ferramentas valiosas para analistas e gestores na tomada de decisões informadas, uma vez que fornecem uma base quantitativa sólida para suas projeções.

A utilização de linhas de tendência também é crucial para a previsão e o planejamento em ambientes industriais, como ressaltado por (DEFEO, 2019). Em contextos industriais, onde a eficiência e o controle de processos são primordiais, a capacidade de prever resultados futuros é fundamental para a otimização de recursos, a melhoria contínua e a minimização de riscos. Linhas de tendência permitem prever, por exemplo, o desempenho de máquinas, o consumo de energia e a demanda por produtos, apoiando a tomada de decisões que impactam diretamente a produtividade e a lucratividade das operações industriais.

2.5 Modelagem Estatística Preditiva

A modelagem estatística preditiva é uma técnica amplamente utilizada para compreender e prever o comportamento de variáveis com base em dados históricos. Dentre os métodos mais comuns estão a regressão linear e a regressão polinomial, que permitem estabelecer relações matemáticas entre variáveis independentes e uma variável dependente.

A regressão linear busca ajustar uma reta aos dados, representando a relação entre duas variáveis. Este modelo assume que a relação entre as variáveis é linear, ou seja, mudanças em X provocam mudanças proporcionais em Y (HARRELL, 2015). Sua equação geral é definida pela Equação 1.

$$Y = \beta_0 + \beta_1 X + \varepsilon \quad (\text{Equação 1})$$

Onde:

Y é a variável dependente;

X é a variável independente;

β_0 é o intercepto;

β_1 é o coeficiente angular;

ε é o erro aleatório.

A regressão polinomial, por sua vez, é uma extensão da regressão linear que permite capturar relações não lineares entre as variáveis. Ela utiliza termos elevados a potências maiores, como quadrado ou cúbico, para ajustar curvas aos dados. Esse tipo de regressão é útil quando os dados apresentam curvaturas que não podem ser representadas adequadamente por uma linha reta (SPRINGER, 1994). Sua forma geral é definida pela Equação 2.

$$Y = \beta_0 + \beta_1 X + \beta_2 X^2 + \beta_3 X^3 + \dots + \varepsilon \quad (\text{Equação 2})$$

Ambos os modelos possuem pressupostos fundamentais que devem ser verificados para garantir a validade das inferências estatísticas. Entre eles estão: a linearidade entre as variáveis (no caso da regressão linear), a independência dos erros, a homocedasticidade (variância constante dos erros), e a normalidade dos resíduos. A violação desses pressupostos pode comprometer a precisão das estimativas e a confiabilidade das previsões (SCHULER, 2006).

Um dos principais indicadores utilizados para avaliar o desempenho dos modelos de regressão é o coeficiente de determinação (R^2). Ele mede a proporção da variabilidade da variável dependente que é explicada pelo modelo. O valor de R^2 varia entre 0 e 1, sendo que valores próximos de 1 indicam que o modelo explica bem os dados. No entanto, um R^2 alto não garante que o modelo seja adequado, especialmente se houver sobreajuste (*overfitting*) ou se os pressupostos forem violados (ISO 50006, 2024).

Por fim, é essencial reconhecer as limitações desses modelos. A regressão linear pode ser inadequada para dados com relações não lineares, enquanto a regressão polinomial, embora mais flexível, pode se tornar complexa e sensível a variações nos dados, especialmente com polinômios de grau elevado. Além disso, ambos os modelos são sensíveis a *outliers*, valores em um conjunto de dados que se distanciam significativamente da tendência geral observada, e à multicolinearidade entre variáveis preditoras (HARRELL, 2015).

3 METODOLOGIA

3.1 Caracterização da Pesquisa

Em termos metodológicos, esse trabalho pode ser classificado como prática e exploratória, com foco na implementação de melhorias específicas no ambiente industrial.

Inicialmente, foi realizada uma revisão bibliográfica abrangente para identificar as definições, ferramentas e etapas necessárias para aplicar técnicas de qualidade voltadas à eficiência energética no contexto da indústria alimentícia. Essa revisão proporcionou a base teórica necessária para desenvolver as ações de melhoria propostas. Segundo (GERHARDT E SILVEIRA, 2009), a pesquisa aplicada é essencial para encontrar soluções práticas para problemas específicos, seguindo uma sequência estruturada que abrange desde a coleta de dados até a formulação e implementação de ações corretivas.

A abordagem adotada neste estudo é quantitativa, fundamentada na análise de dados numéricos que auxiliam na tomada de decisões mais precisas e informadas. Conforme argumentado por (FERNANDES, 2009), métodos quantitativos são amplamente utilizados em áreas como ciências exatas e engenharia, sendo eficazes na classificação, análise e interpretação de dados.

Este estudo assume um caráter descritivo e analítico, ao descrever e interpretar os dados coletados, facilitando a compreensão dos fenômenos observados e permitindo a exploração detalhada do consumo de gás natural na indústria alimentícia.

Os objetivos desta pesquisa são exploratórios, com o intuito de identificar e compreender as características dos fenômenos relacionados ao consumo de gás natural na indústria alimentícia, além de explicar suas causas e suas relações com o problema em questão.


Do ponto de vista dos procedimentos técnicos, este estudo é classificado como uma pesquisa-ação, caracterizada pela participação ativa dos pesquisadores e dos profissionais da empresa na busca por soluções práticas e eficazes.

A pesquisa-ação permite que as melhorias sejam implementadas de forma colaborativa e adaptadas às necessidades específicas da empresa, garantindo maior aderência às soluções propostas.

3.2 Aplicação do PDCA

Este trabalho foi conduzido com base na metodologia do ciclo PDCA (Planejar–Executar–Verificar–Agir), uma abordagem amplamente utilizada na gestão da qualidade para promover melhorias contínuas e sustentáveis nos processos industriais. A aplicação do PDCA permitiu estruturar as etapas do projeto de forma lógica, visando a redução das penalidades financeiras decorrentes do consumo excessivo de gás natural nos fornos de wafer de uma indústria alimentícia. A Figura 9 ilustra um fluxograma do PDCA.

Figura 9 – Fluxograma da aplicação do PDCA.



Fonte: Autor, 2025.

Na etapa de planejamento (Plan), será realizada a coleta dos dados históricos de produção e de consumo de gás natural da planta industrial. Esses dados passarão por tratamento inicial para verificação de consistência e organização em formato adequado às análises. Em seguida, será aplicado um conjunto de ferramentas estatísticas no software Minitab, incluindo histogramas, gráficos de dispersão e modelos de regressão linear e polinomial, utilizados como base metodológica para a formulação de modelos de previsão. Também está prevista a estratificação dos dados por diferentes regimes operacionais, como dias úteis, finais de semana e variações de turno, de modo a possibilitar a análise sob diferentes perspectivas.

Na etapa de execução (Do), serão implementadas as ações planejadas, contemplando a capacitação das equipes envolvidas, a definição de rotinas de comunicação interna acerca dos limites contratuais de gás natural e a implantação de registros sistemáticos de consumo. O uso de modelos estatísticos desenvolvidos no planejamento será incorporado como recurso auxiliar para apoio à programação do consumo de gás em função da produção prevista. Além disso, será instituído um grupo multidisciplinar, composto por representantes das áreas de produção, manutenção e utilidades, responsável por acompanhar o andamento das atividades e garantir a integração entre os setores.

Na etapa de verificação (Check), os dados coletados na execução serão submetidos novamente às ferramentas estatísticas previamente definidas, com a finalidade de realizar a comparação entre registros e parâmetros de referência estabelecidos no planejamento. Essa etapa será conduzida de forma sistemática, garantindo padronização na forma de análise e consistência na aplicação da metodologia.

Na etapa de ação (Act), os procedimentos estabelecidos ao longo do ciclo serão organizados e registrados em documentos formais, assegurando que possam ser incorporados às rotinas operacionais da planta. Também serão elaborados protocolos de acompanhamento contínuo, prevendo reuniões periódicas entre as áreas envolvidas e a manutenção da sistemática de registros. Por fim, está prevista a possibilidade de novos ciclos de PDCA, nos quais poderão ser integradas variáveis adicionais aos modelos, como fatores sazonais e variações de turno de produção.


4 RESULTADOS

4.1 Planejar (*Plan*)

Na etapa de planejamento, foi construída a primeira base de dados, composta pelos registros históricos de consumo de gás natural e volumes de produção da planta industrial no período de janeiro a novembro de 2024. Essa base permitiu compreender as variações existentes e identificar discrepâncias relevantes entre o consumo real e o volume contratado, o que resultava em penalidades aplicadas pela fornecedora de gás.


Os dados foram estratificados em três grupos distintos — dias úteis, sábados e domingos —, considerando as diferenças operacionais em cada período. Com auxílio do software Minitab, foram construídos histogramas e gráficos de dispersão, que evidenciaram padrões distintos de consumo. As Figuras 10 e 11 ilustram os padrões observados para dias úteis.

Figura 10 - Histograma de consumo de gás (m³) para dias úteis.



Fonte: Autor, 2025.


Figura 11 - Histograma de volume (ton) para dias úteis.



Fonte: Autor, 2025.


Analisando os histogramas, observou-se uma concentração dos dados em faixas intermediárias, indicando estabilidade operacional e repetição de condições produtivas semelhantes. Para dar continuidade à análise foram elaborados os histogramas representados nas Figuras 12 e 13, referentes aos dados coletados dos dias de sábados.

Figura 12 - Histograma de consumo de gás (m^3) para sábados.



Fonte: Autor, 2025.


Figura 13 - Histograma de volume (ton) para sábados.



Fonte: Autor, 2025.


Aos sábados, foi possível verificar que a distribuição foi mais dispersa, com maior variabilidade nos volumes e consumos registrados, sugerindo flutuações no volume de produção. Já os dados dos dias de domingo foram ilustrados nas Figuras 14 e 15.

Figura 14 - Histograma de consumo de gás (m³) para domingos.



Fonte: Autor, 2025.

Figura 15 - Histograma de volume (ton) para domingos.



Fonte: Autor, 2025.


A análise dos histogramas permitiu identificar padrões distintos de distribuição para o volume de produção e o consumo de gás nos diferentes grupos. Diferente dos outros dois grupos, os dados dos domingos revelaram uma concentração acentuada em faixas inferiores, tanto para produção quanto para consumo, refletindo uma operação reduzida. Essas diferenças de comportamento entre os grupos reforçam a necessidade de tratá-los separadamente nas análises preditivas.

Ainda na etapa de planejar, com o objetivo de avaliar a correlação entre o volume de produção (toneladas) e o consumo de gás (m³), foram elaborados gráficos de dispersão com ajuste por regressão linear para cada grupo de dias analisado. Os valores de R^2 estão descritos na Tabela 1.

Tabela 1 – Valores de R^2 obtidos na regressão polinomial de primeiro grau.


Grupo	R^2
Dias úteis	80,29%
Sábados	74,83%
Domingos	78,88%

As Figuras 16, 17 e 18 apresentam os gráficos de regressão linear aplicados aos dados de dias úteis, sábados e domingos, respectivamente. O gráfico referente aos dias úteis revelou uma tendência crescente, embora com significativa dispersão dos pontos em torno da linha de tendência, o que indica uma relação não estritamente linear entre produção e consumo. Essa dispersão foi ainda mais acentuada nos sábados, refletindo maior variabilidade no comportamento do consumo e resultando em um coeficiente de determinação (R^2) inferior a 75%. Já nos domingos, apesar dos volumes de produção mais baixos, os dados mostraram uma distribuição mais concentrada, sugerindo maior estabilidade no padrão de consumo, embora sem evidência clara de linearidade.

Figura 16 – Gráfico de regressão linear para dias úteis: Volume *versus* Consumo.


Fonte: Autor, 2025.

Figura 17 – Gráfico de regressão linear para sábados: Volume *versus* Consumo.



Fonte: Autor, 2025.

Figura 18 – Gráfico de regressão linear para domingos: Volume *versus* Consumo.



Fonte: Autor, 2025.

4.2 Executar (Do)

Durante a fase de execução, as iniciativas foram desenvolvidas em dois pilares: execução operacional e análise de dados. Durante a execução operacional, foram adotadas medidas para fortalecer o controle do consumo de gás e garantir maior previsibilidade. A equipe de operação foi treinada quanto à relevância desse controle, e os valores contratados passaram

a ser comunicados regularmente aos responsáveis pelos fornos. Além disso, foi implantado um sistema de monitoramento diário que permite identificar desvios em tempo real e agir de forma imediata. Para garantir a atualização contínua das informações e promover decisões integradas, foi formado um grupo multidisciplinar envolvendo as áreas de produção, manutenção e utilidades.


4.3 Verificar (*Check*)

Na etapa de verificação, os resultados foram analisados com base nas duas fases de modelagem. A primeira base de dados, utilizada na regressão linear, forneceu uma visão inicial da relação entre produção e consumo, mas apresentou limitações em termos de capacidade preditiva. Já a segunda base, aplicada à regressão polinomial de segundo grau, demonstrou avanços significativos: os valores de R^2 (Tabela 2) foram maiores e refletiram com maior precisão o comportamento real do processo. Esse ganho foi visto de maneira mais evidente nos domingos, devido à existência de um padrão de consumo mais estável e previsível, favorecendo a aderência do modelo e a confiabilidade das estimativas.


Tabela 2 – Valores de R^2 obtidos na regressão polinomial de segundo grau.

Grupo	R^2
Dias úteis	82,98%
Sábados	76,73%
Domingos	85,98%

A análise gráfica das Figuras 19, 20 e 21 reforça esses resultados, evidenciando a curvatura capturada pelo modelo polinomial e a melhor aderência aos dados observados.


Figura 19 – Gráfico de regressão polinomial para dias úteis: Volume *versus* Consumo.

Fonte: Autor, 2025.

Figura 20 – Gráfico de regressão polinomial para sábados: Volume *versus* Consumo.

Fonte: Autor, 2025.


Figura 21 – Gráfico de regressão polinomial para domingos: Volume *versus* Consumo.



Fonte: Autor, 2025.

A aplicação prática dessas equações resultou em maior estabilidade no padrão de consumo e em uma redução dos custos associados às penalidades. O monitoramento das multas ao longo do tempo mostrou que, a partir de dezembro de 2024, quando o modelo polinomial foi implementado, houve uma queda contínua e sustentada nas penalidades, acumulando aproximadamente 80% de redução até junho de 2025, conforme verificado na Figura 22.

Figura 22 – Custo com penalidades ao longo dos meses.



Fonte: Autor, 2025.

4.4 Agir (Act)

Na etapa de ação, as boas práticas foram formalizadas e incorporadas à rotina da fábrica devido a eficácia comprovada. O modelo polinomial de segundo grau passou a ser a ferramenta oficial de previsão do consumo, enquanto o monitoramento diário e as reuniões semanais entre as áreas envolvidas foram instituídos como práticas padrão de acompanhamento.

Além disso, foram verificadas oportunidades de melhorias para ciclos futuros, como a inclusão de novas variáveis no modelo (sazonalidade e turnos de operação), de modo a aumentar ainda mais a robustez das previsões.

5 CONCLUSÃO

A segmentação dos dados por grupos de dias (dias úteis, sábados e domingos) foi essencial para compreender o comportamento do consumo de gás em diferentes contextos operacionais. Os histogramas permitiram identificar padrões distintos de distribuição: nos dias úteis, os dados apresentaram maior concentração em faixas intermediárias, refletindo estabilidade produtiva; aos sábados, observou-se maior dispersão, indicando variações operacionais; e aos domingos, os valores se concentraram em faixas inferiores, compatíveis com uma operação reduzida.

A análise por regressão linear demonstrou que a relação entre o volume de produção e o consumo de gás não é adequadamente representada por um modelo linear simples. A dispersão dos pontos em torno da linha de tendência, especialmente nos extremos da produção, indicou baixa capacidade explicativa do modelo, com ausência de alinhamento consistente entre as variáveis.

Diante disso, a aplicação da regressão polinomial de segundo grau mostrou-se mais eficaz. Os modelos ajustados apresentaram coeficientes de determinação (R^2) significativamente superiores aos da regressão linear. Esses resultados evidenciam que a inclusão do termo quadrático foi fundamental para capturar a curvatura presente nos dados e representar com maior precisão a relação entre produção e consumo. Além disso, os modelos polinomiais permitiram estimativas mais confiáveis, contribuindo para uma gestão energética mais eficiente e alinhada às condições reais de operação da planta.

A utilização prática das equações polinomiais desenvolvidas possibilitou a previsão do consumo de gás com base no volume de produção diário, de forma segmentada por tipo de dia. Essa abordagem preditiva permitiu maior assertividade no planejamento do consumo, reduzindo significativamente os desvios em relação ao volume contratado. Como consequência, houve uma diminuição efetiva nas penalidades aplicadas por consumo excedente ou insuficiente, reforçando o impacto positivo da modelagem estatística na otimização de recursos e no desempenho econômico da operação.

Os resultados demonstram que a aplicação estruturada de métodos de melhoria contínua, como o ciclo PDCA, associada ao uso das ferramentas estatísticas adequadas, constitui uma estratégia eficaz para a gestão de recursos e redução de perdas financeiras.

5.1 Contribuições

O projeto contribuiu diretamente para o aprimoramento da gestão energética na planta industrial, oferecendo uma solução prática para prever e ajustar o consumo de gás natural com base na produção. A aplicação de modelos estatísticos permitiu maior precisão nas estimativas e embasou decisões operacionais mais eficientes.

Do ponto de vista acadêmico, a abordagem utilizada reforça o potencial das ferramentas estatísticas na análise de dados industriais e pode servir como referência para estudos futuros sobre consumo energético e otimização de recursos.

Além dos ganhos operacionais, a iniciativa promoveu uma redução significativa de desperdícios e penalidades contratuais, alinhando-se às práticas de sustentabilidade e responsabilidade socioambiental. A melhoria na previsibilidade do consumo contribui para processos mais conscientes e integrados.

Por fim, o projeto contribui com os Objetivos de Desenvolvimento Sustentável (ODS), especialmente os relacionados à inovação na indústria e ao uso responsável de recursos. A experiência obtida abre espaço para novos ciclos de melhoria contínua e para a adição de variáveis adicionais que ampliem o alcance da solução.

REFERÊNCIAS

- ANTUNES, M. de L. *Os 7 Princípios de Gestão da Qualidade*. SGSCorp. 4 mar. 2022.
- ARANTES, R. P. *A Evolução Histórica do Controle de Qualidade: As eras e os gurus da Gestão da Qualidade*. Pt.linkedin.com, 6 abr. 2022.
- BHUIYAN, N.; BAGHEL, A. **An overview of continuous improvement: from the past to the present**. *Management Decision*, v. 43, n. 5, p. 761-771, 2005.
- CAMPOS, V. F. *TQC: Controle da Qualidade Total (no estilo japonês)*. São Paulo: Bloch, 2013.
- CHIAVENATO, I. *Introdução à Teoria Geral da Administração*. São Paulo: McGraw-Hill, 1983.
- COSTA, R. *TQM - Total Quality Management - Portal Gestão*. Portal-Gestao.com, 12 ago. 2019.
- CUSTODIO, L. *Melhoria Contínua: Implementação e Benefícios*. Revista de Gestão Industrial, 2015.
- DEFE, J. *What Is Total Quality Management?* Juran, 23 ago. 2019.
- EPE – EMPRESA DE PESQUISA ENERGÉTICA. *Demanda de Gás Natural nos Mercados Nacional e Internacional: Horizonte 2020-2030*. Nota Técnica EPE/DPG/SPG/09/2020. Rio de Janeiro: EPE, 2020.
- FERNANDES, A. *Métodos Quantitativos para Análise de Dados*. São Paulo: Editora XYZ, 2009.
- FROST, J. *Using Histograms to Understand Your Data*. Statistics By Jim, 11 fev. 2019.
- GERHARDT, T. E.; SILVEIRA, D. T. *Métodos de Pesquisa*. São Paulo: Editora XYZ, 2009.
- GHINATO, P. *Introdução ao Sistema de Produção Enxuta*. Porto Alegre: Bookman, 2000.
- GURUS, Q. *Scatter Plot Graph: What are they and How to Use them*. Quality Gurus, 2021.
- HARRELL, Frank E. **Regression Modeling Strategies: With Applications to Linear Models, Logistic and Ordinal Regression, and Survival Analysis**. Springer Series in Statistics, 2015.
- HASHMI, K. *Introduction and Implementation of Total Quality Management (TQM)*. iSixSigma, 2010.
- HISTOGRAMA. *Ferramentas da Qualidade*, 2016.
- ISO 50006. **ABNT NBR ISO 50006:2024**. São Paulo: ABNT, 2024.

JEYARAMAN, K.; TEO, L. K. **A conceptual framework for critical success factors of lean six sigma: Implementation on the performance of electronic manufacturing service industry.** *International Journal of Lean Six Sigma*, v. 1, n. 3, p. 191-215, 2010.

MOEN, Ron; NORMAN, Cliff. *Evolution of the PDSA Cycle*. Disponível em <http://deming.ces.clemson.edu>. Acesso em 9 de junho de 2007.

NEYESTANI, B. *Seven Basic Tools of Quality Control: The Appropriate Techniques for Solving Quality Problems in the Organizations*. SSRN Electronic Journal, 2017.

ORIBE, C. Y. *PDCA: Origem, conceitos e variantes dessa ideia de 70 anos*.

PALADINI, E. *Gestão da Qualidade: Teoria e Prática*. São Paulo: Atlas, 2004.

PEPPER, M. P.; SPEDDING, T. A. **The evolution of lean six sigma.** *International Journal of Quality & Reliability Management*, v. 27, n. 2, p. 138-155, 2010.

SALAH, S.; RAHIM, A.; CARRETERO, J. A. **The integration of Six Sigma and Lean Management.** *International Journal of Lean Six Sigma*, v. 1, n. 3, p. 249-274, 2010.

SCHULER, Alexandre R. P. *Apostila controle estatístico*. 2006.

SPRINGER. **A Rank-Invariant Method of Linear and Polynomial Regression Analysis**. In: *Statistical Modelling*. Springer, 1994.

SHINGO, S. *Study of the Toyota Production System from an Industrial Engineering Viewpoint*. Nova York: Productivity Press, 1996.

YENTSANG, R.; JOHNSON, H.; MATTHEWS, J. *Kaizen and Continuous Improvement*. *International Journal of Quality Management*, 2010.