57º SBPO
SIMPÓSIO BRASILEIRO DE PESQUISA OPERACIONAL
Gramado • RS
DE 5 A 9 DE OUTUBRO DE 2025

Utilização de um modelo MILP para programação de produção em uma linha de cortes de frango.

Leandro Henrique Gomes da Silva
Instituição: Universidade Federal de Pernambuco
Endereço: Av. Prof. Moraes Rego, 1235 - Cidade Universitária, Recife - PE, 50670-901
e-mail: Leandro.hgsilva@ufpe.br
Thiago Sposito Antonino Tenório
Instituição: Universidade de Pernambuco
Endereço: Av. Gov. Agamenon Magalhães - Santo Amaro, Recife - PE, 50100-010
e-mail: Thiago.sposito@natto-br.com
Jefferson Evair da Silva Andrade
Instituição: Universidade de Pernambuco
Endereço: Av. Gov. Agamenon Magalhães - Santo Amaro, Recife - PE, 50100-010
e-mail: jefferson.andrade@natto-br.com
Lucas Matheus do Nascimento
Instituição: Universidade Federal de Pernambuco
Endereço: Av. Prof. Moraes Rego, 1235 - Cidade Universitária, Recife - PE, 50670-901
e-mail: lucas.matheusn@ufpe.br
Dênis Leite
Instituição: Universidade de Pernambuco
Endereço: Av. Gov. Agamenon Magalhães - Santo Amaro, Recife - PE, 50100-010
e-mail: denisleite@poli.br
Márcio José das Chagas Moura
Instituição: Universidade Federal de Pernambuco
Endereço: Av. Prof. Moraes Rego, 1235 - Cidade Universitária, Recife - PE, 50670-901
e-mail: marcio.cmoura@ufpe.br

RESUMO

A otimização da programação de produção em indústrias é essencial para garantir eficiência operacional e atender às demandas do mercado. Este estudo propõe a implementação de um modelo de programação inteira mista, substituindo ferramentas baseadas em *r*egras empíricas, que apresentam limitações em cenários complexos. O modelo foi desenvolvido em *Python*, utilizando dados reais de uma fábrica, isso possibilitou gerar sequenciamentos ótimos em poucos segundos. Foram modeladas quatro linhas de cortes, incorporando restrições como capacidade, disponibilidade e demanda. Os resultados demonstraram que o modelo reduziu o tempo de planejamento, melhorou a precisão das programações e possibilitou a automação do processo, facilitando a tomada de decisão em tempo real. Após a implementação, a empresa observou um aumento de 27% na produção diária de bandejas após a retomada de operações pós-incêndio.

Palavras-chave: Programação inteira mista, Otimização de produção, Planejamento de produção
Tópicos: Introdução, Revisão de literatura, Metodologia, Análise de resultados,Conclusões.

ABSTRACT

The optimization of production scheduling in industries is essential to ensure operational efficiency and meet market demands. This study proposes the implementation of a mixed-integer programming model to replace tools based on empirical rules, which have limitations in complex scenarios. The model was developed in Python using real data from a factory, enabling the generation of optimal sequences within seconds. Four cutting lines were modeled, incorporating constraints such as capacity, availability, and demand. The results showed that the model reduced planning time, improved scheduling accuracy, and enabled process automation, facilitating real-time decision-making. After implementation, the company observed a 27% increase in daily tray production following the resumption of operations after a fire.

Keywords: Whole mixed programming, production optimization, production planning
Paper topics: Introduction, Literature review, Methodology, Analysis of results, Conclusions.

DOI: 10.59254/sbpo-2025-212474
https://proceedings.science/p/212474?lang=pt-br

1. Introdução

A eficiência operacional e a sustentabilidade econômica nas indústrias alimentícias são temas de crescente importância, especialmente em setores que lidam com produtos perecíveis, como a avícola. O planejamento da produção, nesse contexto, não apenas assegura a qualidade dos produtos, mas também desempenha um papel fundamental na conformidade com normas regulatórias e na satisfação das demandas do mercado [Jaigirdar *et al* 2022]. No entanto, a complexidade do ambiente de produção associado a fatores como a volatilidade da demanda e a imprevisibilidade no fornecimento de matérias-primas traz desafios significativos que precisam ser abordados [Xu *et al* 2023]. Neste cenário, a adoção de ferramentas e métodos apropriados para a programação da produção torna-se crucial para a competitividade das indústrias, que buscam não apenas otimizar seus processos internos, mas também se adaptar de forma ágil às exigências do mercado.

O planejamento da produção configura-se como um pilar estratégico para a eficiência operacional e a sustentabilidade econômica em indústrias alimentícias, destacando-se seu papel crítico em ambientes complexos como as fábricas abatedoras de aves [Kumar *et al* 2022]. Nesse segmento, o sincronismo entre as etapas de abate, processamento e distribuição é vital para garantir a qualidade do produto final, a segurança alimentar e o cumprimento de rigorosas normas sanitárias [K.V. Fedoseeva 2024]. A alta perecibilidade das matérias-primas, a demanda volátil do mercado e a necessidade de redução de desperdícios exigem um planejamento minucioso, capaz de otimizar recursos humanos, tecnológicos e logísticos [LEHA *et al* 2025]. Além disso, a gestão eficiente desses processos assegura a conformidade com padrões regulatórios e a rastreabilidade, fatores essenciais para a competitividade global do setor.

Por tratar-se de produtos perecíveis surgem desafios inerentes à programação diária da produção. Esses produtos necessitam ser enviados rapidamente ao seu cliente e não podem ser estocados. Essa necessidade acaba gerando a necessidade de definir a programação de produção apenas 1 dia após o fechamento das vendas, gerando uma dificuldade de sincronização entre demanda e capacidade operacional. Essa defasagem, somada à volatilidade das vendas e à sazonalidade acentuada amplifica a complexidade do processo. Adicionalmente, restrições de recursos humanos aliadas ao processamento de matéria prima majoritariamente manual, limitam a flexibilidade para ajustes rápidos. Alterações recorrentes na linha de produção, muitas vezes necessárias para atender a pedidos emergentes ou corrigir desvios, geram interrupções que comprometem a produtividade e elevam custos operacionais. Nesse cenário, a ausência de modelos dinâmicos de programação, capazes de integrar dados em tempo real e prever flutuações, torna-se um entrave à otimização contínua.

Diante dos desafios mencionados, evidencia-se que a dependência de ferramentas convencionais, como o *Microsoft Excel*, para o planejamento da produção em larga escala mostra-se insuficiente frente à complexidade operacional de fábricas abatedoras de aves. Na unidade analisada, a utilização do *Excel* para definir a quantidade de produção por turno revelou limitações críticas, especialmente ao integrar múltiplas restrições simultâneas. A ferramenta, embora flexível, demanda esforço manual significativo para atualizações e ajustes, além de carecer de algoritmos robustos para resolver problemas multivariados em tempo hábil. Em cenários de alta complexidade, como alterações repentinas na demanda ou rupturas na cadeia de suprimentos, a programação torna-se inviável ou é realizada de forma desestruturada, gerando planos produtivos subótimos. Essa lacuna técnica resulta em brechas operacionais, como superprodução, ociosidade de recursos ou atrasos na entrega, amplificando desperdícios e comprometendo a eficiência global. A ausência de modelagem preditiva e de integração automática com dados em tempo real reforça a necessidade de migrar para sistemas especializados, capazes de incorporar técnicas de otimização e inteligência operacional, garantindo decisões ágeis e alinhadas às dinâmicas intrínsecas do setor avícola.

Diante das limitações supracitadas, optou-se por migrar a lógica de planejamento empírica para uma modelagem de programação, empregando um modelo de otimização inteira baseado em programação inteira mista. Essa abordagem permite mapear as restrições operacionais da fábrica em uma estrutura matemática rigorosa, capaz de gerar soluções viáveis e ótimas em segundos. Para validar a eficácia da solução proposta, este estudo comparou empiricamente o desempenho do modelo em *Python* com o método tradicional da empresa, analisando métricas como tempo de processamento, redução de desperdícios, aderência aos prazos e utilização de recursos. Os resultados preliminares sugerem que a automação via MIP não apenas acelera a tomada de decisão,

DOI: 10.59254/sbpo-2025-212474
https://proceedings.science/p/212474?lang=pt-br

mas também introduz um padrão replicável para cenários dinâmicos, reforçando a capacidade da indústria em equilibrar eficiência produtiva e adaptabilidade em um mercado altamente competitivo. A transição para essa ferramenta abre precedentes para a modernização de cadeias avícolas, destacando o potencial da ciência de dados na transformação de sistemas produtivos tradicionais.

2. Revisão de literatura

Os sistemas de produção de frigoríficos são caracterizados por sua dependência de matérias-primas sensíveis, regulamentações sanitárias rigorosas e a necessidade de um sequenciamento eficiente das operações. A indústria da carne, uma consumidora significativa de recursos de água doce, gera águas residuais substanciais, necessitando de tratamento eficaz para mitigar os impactos ambientais e garantir a segurança da saúde pública [Ahmad *et al* 2023]. Além disso, os indicadores de sustentabilidade destacam a importância de equilibrar fatores econômicos, sociais e ambientais, enfatizando práticas que minimizem emissões de gases de efeito estufa e o uso da água [Prudencio *et al* 2024]. Além da necessidade de incorporar medidas de bem estar para os trabalhadores que são responsáveis por grande maioria dos processos de produção. Diante desses desafios, o gerenciamento eficiente da cadeia de suprimentos torna-se crucial para manter o fluxo de matérias-primas, enquanto inovações como automação e robótica são adotadas para aumentar a produtividade e contornar a escassez de mão de obra em ambientes de trabalho desafiadores [Acosta-Balseca *et al* 2023][Esper *et al* 2021]. Adicionalmente, práticas de manejo antes do abate influenciam diretamente o bem-estar animal e a qualidade da carne, evidenciando a interconexão entre processos produtivos e resultados finais [Faucitano e Nannoni, 2023].

Nesse contexto, fica evidente a necessidade de abordagens para o planejamento da produção que visam otimizar a eficiência de produção da indústria. Um método proeminente é o planejamento de requisitos de material orientado pela demanda (DDMRP), que integra algoritmos de otimização como a otimização do lobo cinzento (GWO) para aprimorar o gerenciamento de estoque e a capacidade produtiva sob restrições de recursos [Xu *et al*., 2022]. Paralelamente, técnicas de aprendizado por reforço (RL) ganharam força na programação da produção e no gerenciamento de suprimentos, demonstrando adaptabilidade superior a métodos tradicionais [Esteso *et al* 2022]. Complementarmente, algoritmos como a mutação guiada por gradiente NSGA-II oferecem estruturas de planejamento que alinham capacidade produtiva às demandas operacionais, garantindo eficácia em ambientes complexos [Wang e Wang, 2024]. Estes estudos da atualidade mostram como a integração de algoritmos é importante para auxiliar no dia a dia e planejamento operacional da empresa, com sua grande variedade e alta capacidade de resolução. Optou-se seguir com modelo de scheduling para resolver o atual problema da empresa alvo.

Esses modelos de scheduling de produção em ambientes complexos, por sua vez, são sistemas que otimizam alocação de recursos, sequenciamento de operações e atendimento a demandas dinâmicas, considerando restrições como capacidade finita. Operando por meio de algoritmos heurísticos ou de otimização matemática, integram dados em tempo real sobre máquinas, estoques e prazos, gerando soluções que equilibram eficiência e flexibilidade [Pacheco & Santoro, 2001]. Para sua aplicação, é essencial mapear características do processo produtivo compatibilizar arquiteturas de software com sistemas existentes (ERP/SCM) e validar modelos por meio de pilotos que testem parametrização e qualidade das saídas (Pacheco & Santoro, 2001). A adoção desses sistemas justifica-se pela pressão competitiva por redução de custos, confiabilidade em prazos, organização de produção e resposta a flutuações de demanda.

Diante disso, a Programação Linear Inteira Mista (MILP) emerge como ferramenta estratégica na indústria de alimentos, otimizando decisões da cadeia de suprimentos, programação de produção e alocação de recursos. No setor de laticínios, por exemplo, modelos MILP integram decisões de fornecimento e planejamento produtivo, reduzindo custos de transporte e estoque enquanto aumentam eficiência [Emidio *et al* 2021]. Em cadeias de suprimentos de circuito fechado, auxiliam no gerenciamento de itens retornáveis, maximizando lucros ao otimizar tempo e quantidade de compras [Zhang *et al* 2016]. Embora o MILP ofereça soluções exatas e lide sistematicamente com restrições complexas, seus tempos computacionais prolongados em problemas de grande escala e riscos de sobreajuste limitam sua generalização [He *et al* 2021] [Lancia e Serafini 2017]. Mesmo assim, segue-se com a escolha, pois, para o problema atual a quantidade de dados e restrições não demandam um grande esforço computacional para resolver de forma ótima.

DOI: 10.59254/sbpo-2025-212474
https://proceedings.science/p/212474?lang=pt-br

Por fim, para seguir adiante o planejamento eficaz da produção exige a integração de dados reais e a consideração de múltiplas restrições para otimizar resultados. A estrutura híbrida proposta no contexto de refinarias, por exemplo, demonstra que modelos precisos de unidades secundárias podem aumentar a lucratividade em 21,75% e reduzir emissões em 16,67% [Li *et al* 2023]. A análise detalhada de dados em manufatura também é crucial, pois mitiga riscos de saídas anormais e estabelece bases confiáveis para planejamento [Chromjaková *et al* 2023]. Finalmente, reunir dados organizacionais abrangentes é essencial para criar planos eficazes [Hanzaki 2024]. Coletivamente, esses elementos reforçam o papel central das abordagens baseadas em dados e da gestão de restrições para aprimorar a eficácia do planejamento da produção em setores diversos [Völker e Mönch 2023].

3. Metodologia

3.1. Coleta, tratamento dos Dados e formulação de solução

Durante a contextualização da problemática da empresa, um de seus operadores mostrou a ferramenta atual utilizada para realizar a programação de produção, se tratava de uma planilha *Excel* que continha informações como chegada de matéria prima por hora, pessoas disponíveis na linha de produção, crono análise do processo de produção, demanda de cada SKU e outros. A estrutura destes SKUs podem ser visualizadas na Tabela 1.

A linha de produção possui 2 divisórias maiores, onde o frango abatido é separado em matéria prima para cortes ou para inteiros. Das unidades classificadas como corte serão separadas para 4 linhas, asa, peito, perna e filé. A ferramenta *Excel* utilizada no momento era capaz de entregar um sequenciamento para as linhas de filé e peito, mas não para asa e perna, segundo o operador, a quantidade de SKU era muito superior, o que trazia uma grande limitação na elaboração da lógica de cálculos do *Excel*.

Diante disso, iniciou-se o pré-processamento, onde foi feito um filtro em todos os dados úteis e necessários de serem utilizados em um modelo de programação inteira. O detalhamento dos dados coletados pode ser visto na Tabela 2.

Através do trabalho de [Nascimento *et a*l 2024] pode-se obter mais detalhes do procedimento de produção através de uma modelagem de simulação utilizando o *Flexsim*.

Tabela 1 – Quantidade de SKU em cada categoria na linha de produção

	Bandeja 700g/1kg	**Pacote 5kg**	**Matéria-Prima congelada/resfriada**	**Individual**	**Desossa**
Filé de peito	7	2	8	1	0
Peito	8	2	1	1	0
Asa	20	12	9	1	0
Perna	13	11	8	3	1

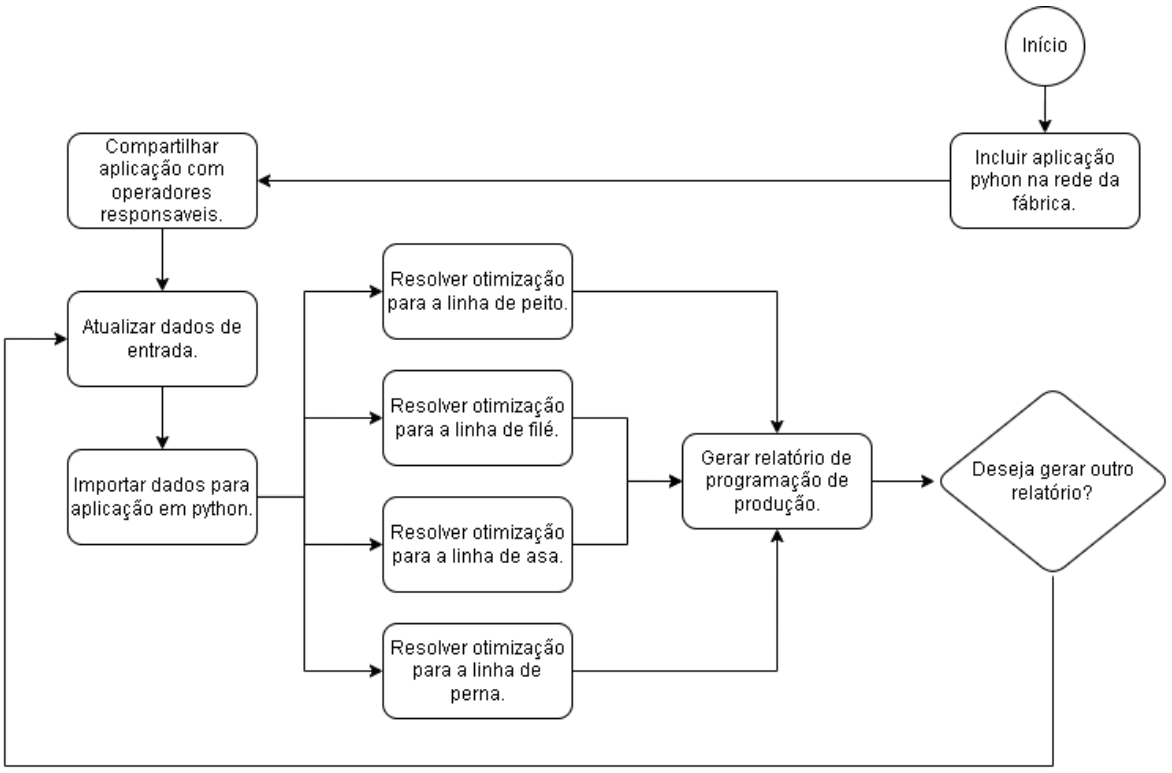
Tabela 2 – Dados coletados para realizar otimização

Dados de produto	Categoria do produto	Subcategoria do produto	SKU do produto	Nome do produto	Demanda diária do produto
Dados de matéria prima	Previsão de matéria prima disponível por hora para cada categoria de produto				
Dados de capacidade de trabalho	Capacidade de produção de cada grupo de trabalho pertencente a linha				
Cronoanálise	Quantidade de produtos feitos por minutos por operador em linha.				

DOI: 10.5540/sbpo-2025-212474
https://proceedings.science/p/212474?lang=pt-br

Com os dados em mãos, em conjunto com os operadores iniciou-se o planejamento para elevar o nível da programação de produção da empresa, optou-se por utilizar programação inteira por ser uma alternativa útil e adequada a realidade da empresa, a possibilidade de usar *python* facilita a implementação e testes de resultados. Além disso, também foi requerido criar uma interface que mostre os resultados gerados pela otimização e que possibilite o operador imprimir e/ou compartilhar com outras pessoas dentro da rede da fábrica. Com isto em mente optámos por seguir o procedimento mostrado na Figura 1 para resolução dos problemas apresentados.

Figura 1 – Fluxo de implementação do modelo de otimização



No fim deste planejamento, deve ser entregue uma ferramenta que utiliza dados reais de fábrica para criar uma programação proveniente de uma programação inteira, ou seja, retorna um resultado otimizado para a fábrica, respeitando todas as restrições impostas, em um tempo curto e de forma automatizada, além de facilitar o compartilhamento e uso conjunto de mais de um operador ao mesmo tempo.

3.2. Formulação Matemática do Problema

Inicialmente cada linha de corte é tratada com um modelo de otimização independente, sendo assim, temos 4 modelos a serem resolvidos, sendo o das linhas de asa e perna mais complexos por necessitar de restrições extras para tratar das especificidades do processo de produção. Porém existem similaridades do processo entre a linha de peito e filé de peito e também da linha de perna entre a linha de asa. A seguir iremos descrever cada modelo de otimização resolvido.

3.2.1. Modelo de otimização da linha de filé

O modelo é baseado em conjuntos que representam categorias de produtos (C), suas subcategorias (S), SKUs específicos ($P_{c,s}$) e horários de produção (K). Os parâmetros incluem prioridades de produção ($P_{c,s,i}$), capacidades das equipes ($Cap_{equip,k}$), demandas máximas ($d_{c,s,i}$) e disponibilidade de matéria-prima ($M_{I1,k}M_{I2,k}$). As variáveis de decisão , $X_{c,s,i,k}$, indicam a quantidade produzida de cada SKU em um dado horário, sendo inteiras e não negativas.

A função objetivo do modelo busca maximizar a prioridade ponderada pela produção de cada SKU, ajustada pelo horário de produção. Matematicamente, é expressa como:

DOI: 10.59254/sbpo-2025-212474
https://proceedings.science/p/212474?lang=pt-br

$$Max\ Z = \sum_{c \in C} \sum_{s \in S} \sum_{i \in P_{c,k}} \sum_{k \in K} \frac{P_{c,s,i} * X_{c,s,i,k}}{k+1} \quad (1)$$

onde pc,s,i representa a prioridade do SKU i, $X_{c,s,i,k}$ é a quantidade produzida no horário k, e o termo $\frac{1}{k+1}$ penaliza a produção em horários mais tardios, incentivando uma alocação mais eficiente ao longo do tempo. Isto está sendo considerado devido um requisito de produção pedido pela empresa.

As restrições garantem a viabilidade operacional do modelo. Primeiro, as capacidades das equipes são respeitadas por meio de limites máximos para a produção total atribuída a cada equipe em um dado horário. Matematicamente, é expressa como:

$$\sum_{s \in Bandeja700g} \sum_{i \in Bandeja700g} X_{bandeja700g,s,i,k} + \sum_{s \in Bandeja1kg} \sum_{i \in Bandeja1kg} X_{bandeja700g,s,i,k} \leq Cap_{Equipe1,k}, \forall k \in K (2)$$

$$\sum_{s \in Pacote} \sum_{i \in Pacote} X_{Pacote,s,i,k} \leq Cap_{Equipe2,k}, \forall k \in K\ (3)$$

$$\sum_{s \in MP} \sum_{i \in MP} X_{MP,s,i,k} \leq Cap_{Equipe3,k}, \forall k \in K\ (4)$$

Segundo, a demanda máxima de cada SKU é considerada, assegurando que a produção não exceda os níveis requeridos. É considerado ótimo um sequenciamento de produção que atende o máximo de demanda possível dos produtos mais prioritários, sendo assim, não atender toda demanda disponível não é considerado um cenário ruim. Matematicamente, é expressa como:

$$\sum_{k \in K} X_{c,s,i,k} \leq d_{c,s,i}\ (5)$$

Finalmente, a disponibilidade de matéria-prima (M_I) é controlada por restrições que limitam a produção total em função da chegada de insumos nos horários correspondentes. Matematicamente, é expressa como:

$$\sum_{s \in Bandeja700g} \sum_{i \in Bandeja700g} X_{bandeja700g,s,i,k} + \sum_{s \in Bandeja1kg} \sum_{i \in Bandeja1kg} X_{bandeja700g,s,i,k} + \sum_{s \in Pacote} \sum_{i \in Pacote} X_{Pacote,s,i,k} +$$

$$\sum_{i \in Sassami700g} X_{Sassami700g,i,k} + \sum_{i \in Sassami1kg} X_{Sassami1kg,i,k} \leq M_{I2,k}, \forall k \in K\ (7)$$

Por fim, a restrição de não negatividade e integralidade das variáveis de decisão, expressa como:

$$X_{c,s,i,k} \in Z_+\ (8)$$

Essas condições são formalizadas matematicamente para integrar múltiplas dimensões do problema, garantindo soluções factíveis e alinhadas aos objetivos estratégicos.

3.2.2. Modelo de otimização da linha de peito

A linha de produção de peito tem a mesma formulação da linha de produção de filé, porém a otimização é feita para uma lista de SKUs diferentes da anterior, além disso a linha de peito não conta com produtos de categoria sassami. Sendo assim esta modelagem compartilha da mesma função objetivo (1), mesma restrição de demanda (5), disponibilidade (6) e capacidade de produção(2,3,4). Suas diferenças são a exclusão da categoria sassami 700g/1kg e adição da categoria “Individual”, sendo assim, esta linha conta com 4 equipes de trabalho para realização de todo o procedimento.

3.2.3. Modelo de otimização da linha de perna

Para o modelo de otimização da linha de perna existem algumas alterações que foram necessárias incorporar para refletir a realidade da produção. Este modelo compartilha da mesma função objetivo e variáveis de decisão dos modelos mostrados anteriormente, porém, com algumas adições. Variáveis binárias auxiliares foram introduzidas para capturar decisões lógicas relacionadas ao processo produtivo, mais especificamente a decisão de corte, pois uma perna inteira de frango pode ser cortada e transformada e coxa e sobrecoxa, para refletir esta decisão no modelo utilizamos

DOI: 10.5540/sbpo-2025-212474
https://proceedings.science/p/212474?lang=pt-br

a variável $corte_ativado_k$ que indica se o processo de corte da perna inteira está ativado no horário k. Variáveis como $prod_bandeja_coxa_k$, $prod_bandeja_sobrecoxa_k$, e outras similares indicam se uma subcategoria específica está sendo produzida no horário k. Essas variáveis binárias permitem modelar condições de exclusividade e dependência entre diferentes tipos de produção, garantindo que certas combinações de atividades não ocorram simultaneamente.

Já em relação às restrições, são mantidas as restrições de capacidade de trabalho com 5 equipes, adição da equipe de desossa. A restrição de disponibilidade de matéria prima sofre uma pequena alteração, pois quando há necessidade de corte os produtos oriundos do corte tem uma porcentagem da disponibilidade total da perna inteira, sendo destinado 45% para coxa e 55% para sobrecoxa. Esta restrição pode ser expressa como:

$$\sum_{c,s,i} X_{c,s,i,k} \leq M_{I5,k} * (1 - corte_ativado_k) \ , \forall k \in K \ (perna\ inteira) \ (9)$$

$$\sum_{c,s,i} X_{c,s,i,k} \leq 0,45 * M_{I5,k} * (corte_ativado_k) \ , \forall k \in K \ (Coxa) \ (10)$$

$$\sum_{c,s,i} X_{c,s,i,k} \leq 0,55 * M_{I5,k} * (corte_ativado_k) \ , \forall k \in K \ (Sobrecoxa) \ (11)$$

$$corte_ativado_k \in \{0,1\} \ (12)$$

A restrição de demanda segue sem alterações, mas algumas novas restrições surgem, são as restrições de exclusividade de produção que garantem que certos tipos de produção não ocorram simultaneamente. Por exemplo, a produção de bandejas de coxa exclui a produção de matéria-prima ou pacotes de coxa/perna inteira no mesmo horário, pois um item cortado é direcionado apenas a uma equipe na linha de produção, esta restrição é expressa como:

$$prod_bandeja_coxa_k + mp_perna_inteira_k \leq 1. \ \forall k \in K \ (13)$$

$$prod_{c,s,k} \in \{0,1\} \ (14)$$

Esta lógica segue para cada par de tipo de produtos, como mostra a Figura 2.

Figura 2 – Restrições de exclusividade de produção em python

```
# --- Restrições ---
for k in range(num_horarios):
    model += prod_bandeja_coxa[k] + prod_mp_perna_inteira[k] <= 1
    model += prod_bandeja_coxa[k] + prod_pacote_coxa[k] <= 1
    model += prod_bandeja_coxa[k] + prod_pacote_perna_inteira[k] <= 1

    model += prod_bandeja_sobrecoxa[k] + prod_mp_perna_inteira[k] <= 1
    model += prod_bandeja_sobrecoxa[k] + prod_pacote_sobrecoxa[k] <= 1
    model += prod_bandeja_sobrecoxa[k] + prod_pacote_perna_inteira[k] <= 1

    model += prod_bandeja_coxa[k] + prod_bandeja_sobrecoxa[k] + prod_bandeja_perna_inteira[k] <= 1
    model += prod_pacote_coxa[k] + prod_pacote_sobrecoxa[k] + prod_pacote_perna_inteira[k] <= 1
    model += prod_mp_coxa[k] + prod_mp_perna_inteira[k] <= 1
    model += prod_mp_sobrecoxa[k] + prod_mp_perna_inteira[k] <= 1
```

Além disso também existe uma restrição para identificar se houve decisão de realizar corte na asa inteira ou não em um determinado horário K, que pode ser expressa como:

$$\sum_{s \in (coxa, Sobrecoxa)} \sum_{i \in P_{c,k}} X_{c,s,i,k} \leq Corte_ativado_k * M \ , \forall k \in K \ (15)$$

Onde M é um valor muito grande..

E por fim uma restrição para ativação de variáveis binárias que são ativadas quando há produção em uma subcategoria específica. Por exemplo:

$$\sum_{i \in P(bandeja700g,Coxa)} X_{bandeja700g,coxa,i,k} \leq prod_{bandeja,coxa,k} * M \ , \forall k \in K \ (16)$$

A mesma restrição é repetida para outros pares de categorias e subcategorias de produtos.

DOI: 10.59254/sbpo-2025-212474
https://proceedings.science/p/212474?lang=pt-br

3.2.4. Modelo de otimização da linha de asa

O modelo de otimização da linha de asa segue um procedimento parecido com o modelo de otimização da linha de perna, suas principais diferenças são que a perna pode ser cortada em 2 produtos diferentes a coxa e sobrecoxa, já a asa pode ser cortada em 3 produtos diferentes a coxinha, meio e ponta e meio da asa. Sendo assim o modelo compartilha com a mesma lógica, porém com alguns ajustes para refletir a realidade da linha de produção.

A restrição de exclusividade de produção agora é feita com 3 produtos ao invés de 2. A restrição de capacidade continua a mesma, com 5 equipes, porém sem a equipe de desossa e segregação de categoria matéria prima para MP congelado e MP resfriado. Agora existem 2 possibilidades de cortes, uma asa inteira pode ser transformada em coxinha e meio de asa ou em coxinha e ponta e meio da asa, onde cada subproduto equivale a 50% do peso total da asa. Por fim a restrição para ativação das variáveis binárias e a restrição de demanda segue com uma alteração específica na demanda de 2 produtos que são usados para destinar sobras de itens cortados ou não após atender a demanda de seu SKU, logo estes dois itens podem ter produção além do valor da sua demanda.

3.3. Implementação do Modelo de Programação Inteira Mista

Para facilitar os objetivos de implementação utilizamos a biblioteca *streamlit* do *python*, pois com sua utilização é possível hospedar a aplicação direto da rede do usuário, permitindo que qualquer operador que tenha acesso a rede específica consiga usufruir da ferramenta, além de facilitar o compartilhamento de relatórios. Todo o modelo de otimização foi feito utilizando a biblioteca *PuLP* para modelagem e resolução do modelo de programação inteira , por fim é gerado uma tabela formatada que mostra visualmente quais demandas foram atendidas ou não, além de mostrar se todos os requisitos foram satisfeitos e se houver sobra de matéria prima para o sequenciamento gerado, além de permitir salvar os relatórios em formato PDF.

4. Análise de resultados

A aplicação foi testada em cenários com dados reais para validar se os resultados obtidos eram condizentes com a realidade de produção, foi um processo de implementação iterativa, toda a construção do modelo durou cerca de 4 meses, tempo necessário para construir a primeira versão do aplicativo, no qual poderia ser usado por todos os operadores responsáveis do local. As restrições de exclusividade, corte, disponibilidade, capacidade e demanda foram atendidas, sempre priorizando a produção de SKUs com maior prioridade.

Além disso, a partir desta aplicação agora é possível realizar a programação de produção da linha de perna e de asa, o que antes não era possível de ser feito utilizando a ferramenta *Excel* utilizada pelos operadores. Este procedimento agilizou e melhorou muito o dia a dia, segundo os próprios operadores. Em relação ao desempenho da aplicação o *PuLP* utiliza o *CBC MILP Solver*, utilizando o seguinte *hardware:16gb RAM, Intelcore i5-12500H 4.2Ghz, Geoforce RTX 3050 4VRAM*, temos os seguinte resultados, os sequenciamentos podem ser vistos nas Tabelas 3 a 6. As tabelas apresentam a quantidade de caixas para o determinado SKU a ser produzido em cada hora, na coluna total verifica se a quantidade produzida atende a demanda ou não, indicando em vermelho caso a demanda não seja completamente atendida, nas linhas em que indica o total equipe mostra quantas caixas cada equipe está produzindo hora e hora, e verifica se a quantidade alocada respeita a restrição de capacidade de equipe e mostra em vermelho quando a capacidade não é respeitada. Por fim, a linha total geral indica a quantidade de matéria prima utilizada em cada hora, e será mostrado em vermelho caso a quantidade utilizada seja maior que a disponível a ser processada.

Tabela 3 – Sequenciamento de produção da linha de filé

Descrição do Produto	Hora 1	Hora 2	Hora 3	Hora 4	Hora 5	Hora 6	Hora 7	Hora 8	Hora 9	Hora 10	Total	Demanda
1782-FILÉ DE PEITO RESF BDJ 700G X14 CX9,8KG PL	277.0										277.0	277.0
1795-BIFFI FILÉ DE PEITO IN NATURA RESF BDJ 700G X14 CX9,8KG PL	2.0										2.0	2.0
1127-FILÉ DE PEITO CONG BDJ 1KG X12 CX12KG	25.0	185.0	90.0								300.0	300.0
1018-FILÉ DE PEITO RESF GRN 5KG X4 CX20KG PL			57.0	107.0							164.0	164.0
1807-FILÉ DE PEITO RESF GRN 5KG X4 CX20KG				4.0	111.0		57.0				172.0	171.0
1683-MP FILÉ DE PEITO TEMP RESF CX25KG							43.0	65.0			108.0	108.0

DOI: 10.59254/sbpo-2025-212474
https://proceedings.science/p/212474?lang=pt-br

PL												
1739-MP PEITO S/OSSO RESF CX24,25KG PL								25.0	75.0		100.0	100.0
1673-MP FILÉ DE PEITO IN NATURA IQF RESF CX25KG									16.0	89.0	105.0	110.0
1674-MP SASSAMI IN NATURA IQF RESF CX25KG											0	70
(Total, 'Equipe 1')	304.0	185.0	90.0								579.0	
(Total, 'Equipe 2')			57.0	111.0	111.0		57.0				336.0	
(Total, 'Equipe 3')							43.0	90.0	91.0	89.0	313.0	
(Total geral.)	304.0	185.0	147.0	111.0	111.0		100.0	90.0	91.0	89.0	1228.0	

Tabela 4 – Sequenciamento de produção da linha de peito

Descrição do Produto	Hora 1	Hora 2	Hora 3	Hora 4	Hora 5	Hora 6	Hora 7	Hora 8	Hora 9	Hora 10	Total	Demanda
1789-PEITO S/ PELE RESF BDJ 700G X14 CX9,8KG PL	81.0	59.0	46.0								186.0	186.0
1784-PEITO RESF BDJ 700G X14 CX9,8KG PL			14.0	59.0	8.0						81.0	81.0
1806-PEITO RESF GRN 5KG X4 CX20KG					25.0		29.0	29.0			83.0	83.0
1007-PEITO RESF GRN 5KG X4 CX20KG PL									29.0	29.0	58.0	120.0
1010-PEITO TEMP RESF GRN 5KG X4 CX20KG PL											0	3.0
(Total, 'Equipe 1')	81.0	59.0	60.0	59.0	8.0						267.0	
(Total, 'Equipe 2')					25.0		29.0	29.0	29.0		141.0	
(Total geral.)	81.0	59.0	60.0	59.0	33.0		29.0	29.0	29.0		408.0	

Tabela 5 – Sequenciamento de produção da linha de perna

Descrição do Produto	Hora 1	Hora 2	Hora 3	Hora 4	Hora 5	Hora 6	Hora 7	Hora 8	Hora 9	Hora 10	Total	Demanda
1690-MP COXA E SOBRECOXA S/ OSSO C/ PELE RESF CX20KG PL	47.0	34.0	50.0	34.0	50.0		50.0	34.0	21.0		320.0	320.0
1788-SOBRECOXA S/ PELE RESF BDJ 700G X14 CX9,8KG PL	75.0										75.0	75.0
1781-SOBRECOXA RESF BDJ 700G X14 CX9,8KG PL	57.0										57.0	57.0
1780-STEAK FILE SOBRECOXA S/ PELE RESF BDJ 700G X14 CX9,8KG PL	57.0	42.0									99.0	99.0
1786-COXA RESF BDJ 700G X14 CX9,8KG PL			39.0								39.0	39.0
1809-COXA RESF GRN 5KG X4 CX20KG	46.0										46.0	46.0
1043-COXA RESF GRN 5KG X4 CX20KG PL	30.0	55.0									85.0	85.0
1810-SOBRECOXA RESF GRN 5KG X4 CX20KG								68.0	36.0		104.0	104.0
1047-SOBRECOXA RESF GRN 5KG X4 CX20KG PL									40.0	49.0	89.0	89.0
1808-COXA E SOBRECOXA RESF GRN 5KG X4 CX20KG			85.0	78.0							163.0	163.0
1039-COXA E SOBRECOXA RESF GRN 5KG X4 CX20KG PL				46.0	98.0						144.0	144.0
1055-STEAK FILE SOBRECOXA S/ PELE RESF GRN 5KG X4 CX20KG										14.0	14.0	14.0
1028-SOBRECOXA TEMP RESF GRN 5KG X4 CX20KG PL		47.0								5.0	52.0	53.0
1821-SOBREC										22.0	22.0	25.0

DOI: 10.59254/sbpo-2025-212474
https://proceedings.science/p/212474?lang=pt-br

OXA TEMP RESF GRN 5KG X4 CX20KG											
1776-SOBRECOXA S/ OSSO TEMP RESF BDJ TMS 700G X14 CX9,8KG PL										0	6.0
1024-COXA E SOBRECOXA TEMP RESF GRN 5KG X4 CX20KG PL					5.0		52.0			57.0	57.0
1727-COXA E SOBRECOXA TEMP RESF GRN 5KG X4 CX20KG							2.0			2.0	2.0
1653-MP COXA IN NATURA RESF CX25KG								45.0	50.0	59.0	154.0	inf
(Total, 'Equipe 1')	189.0	42.0	39.0								270.0	
(Total, 'Equipe 2')	76.0	55.0	85.0	124.0	98.0			68.0	76.0	63.0	645.0	
(Total, 'Equipe 3')		47.0			5.0		54.0	45.0	50.0	86.0	287.0	
(Total, 'Equipe 5')	47.0	34.0	50.0	34.0	50.0		50.0	34.0	21.0		320.0	
(Total geral.)	312.0	178.0	174.0	158.0	153.0		104.0	147.0	147.0	149.0	1522.0	

Tabela 6 – Sequenciamento de produção da linha de asa

Descrição do Produto	Hora 1	Hora 2	Hora 3	Hora 4	Hora 5	Hora 6	Hora 7	Hora 8	Hora 9	Hora 10	Total	Demanda
1415-MEIO DA ASA RESF BDJ 700G X14 CX9,8KG PL		50.0									50.0	50.0
1676-COXINHA DA ASA RESF BDJ 700G X14 CX9,8KG PL					50.0						50.0	50.0
1781-MEIO DA ASA RESF BDJ 700G X14 CX9,8KG PL		1.0					2.0				3.0	3.0
1785-ASA RESF BDJ 700G X14 CX9,8KG PL	55.0										55.0	55.0
1792-COXINHA DA ASA RESF BDJ 700G X14 CX9,8KG PL					1.0						1.0	7.0
1066-ASA RESF GRN 5KG X4 CX20KG PL	41.0		50.0	24.0							115.0	114.0
1069-COXINHA DA ASA RESF GRN 5KG X4 CX20KG PL		25.0					25.0	6.0			56.0	55.0
1814-ASA RESF GRN 5KG X4 CX20KG				24.0							24.0	24.0
1815-COXINHA DA ASA RESF GRN 5KG X4 CX20KG								19.0	22.0		41.0	41.0
1816-PONTA E MEIO DA ASA RESF GRN 5KG X4 CX20KG											0	3.0
1811-MEIO DA ASA RESF GRN 5KG X4 CX20KG PL					18.0						18.0	18.0
1776-SOBRECOXA ASA TEMP RESF GRN 5KG X4 CX20KG PL				2.0						21.0	23.0	23.0
1148-ASA CONG IND CX18KG										32.0	32.0	32.0
(Total, 'Equipe 1')	55.0	51.0			51.0		2.0				159.0	
(Total, 'Equipe 2')	41.0	25.0	50.0	48.0	18.0		25.0	25.0	22.0		254.0	
(Total, 'Equipe 4')				2.0						21.0	23.0	
(Total, 'Equipe 5')										32.0	32.0	
(Total geral.)	96.0	76.0	50.0	50.0	69.0		27.0	25.0	22.0	53.0	468.0	

Modelo de filé foi resolvido em 0.02s, modelo de peito foi resolvido em 0.05s, modelo de perna foi resolvido em 0.92s e o modelo de asa foi resolvido em 1.43s, totalizando 2,42s para resolvê-

DOI: 10.59254/sbpo-2025-212474
https://proceedings.science/p/212474?lang=pt-br

todos os modelos e disponibilizar um relatório completo e online para a fábrica. As tabelas mostram resultados do último dia de testes, porém várias instâncias de dados reais foram testadas e analisadas, comprovando a eficiência e robustez da ferramenta.

5. Conclusões

5.1. Conclusões Principais

Após analisar os resultados obtidos concluímos que a implementação desta ferramenta de otimização elevou o nível da programação de produção da empresa, entregando uma ferramenta útil, avançada e única para a realidade encontrada dentro do processo produtivo. Esta ferramenta possibilitou programações de produção antes impossíveis, além de agilizar todo o processo de outras programações, de forma automática e com dados reais da empresa. Logo após a implementação do aplicativo na rotina da fábrica ocorreu um triste evento de incêndio, segundo seus gerentes esta ferramenta os ajudou na retomada das operações, chegando a aumentar em até 27% de sua produção de bandejas no dia a dia, o que ajudou a fábrica a se reerguer em um momento delicado, além de facilitar a tomada de decisão no dia a dia para seus operadores.

5.2. Limitações do Estudo

Todas as limitações encontradas estão nos dados utilizados como entrada do modelo de otimização, alguns dados são projeções e/ou expectativa, como por exemplo a disponibilidade de matéria prima em horas futuras, por não ser um valor 100% correto pode infligir a erros que podem afetar a programação de produção. Este e outros dados devem ser melhor estudados para que seus números não gerem erros em tomadas de decisão.

5.3. Sugestões para Trabalhos Futuros

Como sugestão de trabalho futuros temos ideias para elevar o nível de decisão no modelo de otimização, projetamos criar um aplicativo capaz de gerar um sequenciamento de produção ótimo que utilize a menor quantidade de pessoas necessárias na linha de produção. Além disso, o modelo também deve ser capaz de otimizar a separação da quantidade de frangos que serão encaminhados para o setor de cortes e para o setor de inteiros, aumentando assim a complexidade e elevando o nível da tomada de decisão da empresa. Melhorias de interface e usabilidade do aplicativo também estão em projetos futuros, além disso é avaliado a conexão do aplicativo ao banco de dados da empresa, para utilizar dados reais sem necessidade do operador atualizar os dados de forma manual, agilizando ainda mais o procedimento.

6. Agradecimentos

Agradecemos pelo apoio financeiro do Programa de Recursos Humanos da Agência Nacional do Petróleo, Gás Natural e Biocombustíveis – PRH-ANP, o qual foi fundamental para o desenvolvimento deste trabalho. Também gostaria de agradecer a empresa e seus colaboradores, por cooperar e se empenhar no desenvolvimento de suas etapas, me auxiliando nos resultados obtidos. Por fim, gostaria de agradecer também ao apoio do Instituto de Inovação Tecnológica da UPE e a toda minha equipe pelo carinho, incentivo e insights gerados para melhorar ainda mais os resultados obtidos.

Referências

ACOSTA-BALSECA, B. S. et al. Supply chain in the food industry in the meat sector. **Athenea**, p. 17–24, 13 set. 2023.

Ahmad, F., Pathak, V., & Singh, A. (2023). Effect of slaughterhouse waste on sewage channel. **World Journal Of Advanced Research and Reviews**, v. 19, n. 3, p. 1227–1236, 30 set. 2023.

CHROMJAKOVA, F.; BOBAK, R.; HRBACKOVA, L. Production Planning based on Relevant Data Analytics. p. 77–82, 11 ago. 2023.

DE MEDEIROS ESPER, I.; FROM, P. J.; MASON, A. Robotisation and intelligent systems in abattoirs. **Trends in Food Science & Technology**, v. 108, p. 214–222, 1 fev. 2021.

EMIDIO, J. et al. How can mixed integer linear programming assist dairy manufacturers by

DOI: 10.59254/sbpo-2025-212474
https://proceedings.science/p/212474?lang=pt-br

integrating supply decisions and production planning? **Journal of Agribusiness in Developing and Emerging Economies**, v. 11, n. 2, p. 178–193, 24 fev. 2021.

ESTESO, A. et al. Reinforcement learning applied to production planning and control. **International Journal of Production Research**, p. 1–18, 6 ago. 2022.

FAUCITANO, L.; NANNONI, E. Pig production systems and related effects on pre-slaughter animal welfare and meat quality. **Italian Journal of Animal Science**, v. 22, n. 1, p. 513–523, 31 maio 2023.

JAIGIRDAR, S. M. et al. Multi-objective multi-echelon distribution planning for perishable goods supply chain: a case study. **International Journal of Systems Science: Operations & Logistics**, p. 1–19, 4 jan. 2022.

KUMAR, P. et al. New insights in improving sustainability in meat production: opportunities and challenges. **Critical Reviews in Food Science and Nutrition**, v. 63, n. 33, p. 1–29, 12 jul. 2022.

K.V. FEDOSEEVA. PRODUCT SAFETY IN THE MEAT PROCESSING INDUSTRY: MODERN STANDARDS AND QUALITY CONTROL TECHNOLOGIES. p. 50–51, 1 jan. 2024
LANCIA, G.; SERAFINI, P. Integer Linear Programming. **EURO Advanced Tutorials on Operational Research**, p. 43–66, 2 set. 2017.

LEHA, O.; SIRENKO, I.; TARANENKO, Y. MANAGEMENT OF MATERIAL AND TECHNICAL RESOURCES SUPPLY PROCESSES: THEORETICAL FOUNDATIONS AND PRACTICAL APPROACHES. **Economic scope**, n. 196, p. 40–49, 17 jan. 2025.

LI, J. et al. An integrated data-driven modeling and gas emission constraints for large-scale refinery production planning framework. **Process Safety and Environmental Protection**, v. 182, p. 109–126, 27 nov. 2023.

MILAD ZAREI HANZAKI. Production Planning for Manufacturing of Car Parts. 30 ago. 2024.

NASCIMENTO, L. M. et al. MODELING AND SIMULATION OF A CUTTING LINE IN A REFRIGERATOR FOR LINE CONTROL USING FLEXSIM. **Anais do Simpósio Brasileiro de Pesquisa Operacional**, v. Vol 56, 2024, 2024.

PRUDENCIO, D. L.; KORRES, A. M. N.; CARNEIRO, Á. P. Sustainability indicators in beef slaughterhouses: a systematic review. **Desarrollo Local Sostenible**, v. 17, n. 57, p. e1552, 12 jul. 2024.

RICARDO FERRARI PACHECO; MIGUEL CEZAR SANTORO. A adoção de modelos de scheduling no Brasil: deficiências do processo de escolha. **Gestão & Produção**, v. 8, n. 2, p. 128–138, 1 ago. 2001.

VÖLKER, T.; LARS MÖNCH. Data-Driven Production Planning Formulations with Inventory Considerations. **2018 Winter Simulation Conference (WSC)**, p. 2218–2229, 10 dez. 2023.

XU, G. et al. An efficient production planning approach-based demand driven MRP under resource constraints. **International Journal of Industrial Engineering Computations**, v. 14, n. 3, p. 451–466, 1 jan. 2023.

YANG, J.; WANG, A. A Main Production Planning Algorithm Based on Limited Resource Capacity Pools. **2022 IEEE International Conference on Mechatronics and Automation (ICMA)**, p. 1153–1158, 4 ago. 2024.

ZHANG, Y.; CHU, F.; CHE, A. A mixed integer linear programming approach for closed-loop food supply chain with returnable transport items. **Archives-ouvertes.fr**, 29 out. 2016. DOI: 10.59254/sbpo-2025-212474
https://proceedings.science/p/212474?lang=pt-br