

USANDO GRIDS COMPUTACIONAIS EM PROBLEMAS DE MIX ESTOCÁSTICOS: UM ESTUDO DE CASO NA INDÚSTRIA DE PLÁSTICOS

Luiz Rossi de Souza (CEFET)

luizrossi@gmail.com

Rafael Garcia Barbastefano (CEFET)

barbastefano@gmail.com

Diego Moreira de Araujo Carvalho (CEFET)

d.carvalho@ieee.org



Uma fábrica de filme plástico polipropileno bi-orientado (BOPP), para se manter competitiva, tem que ser capaz de produzir algumas centenas de produtos, variando em gramatura, coloração e corte de modo a atender novas exigências do mercado consumidor. Este trabalho apresenta uma técnica para a análise do problema Mix de Produto Estocástico, buscando maximizar as margens de contribuição em uma empresa fabricante de BOPP. Usando uma modelagem baseada em Programação Inteira Mista Estocástica, o problema de mix foi resolvido usando uma infraestrutura de Grade Computacional de 1200 processadores. Os resultados indicaram a possibilidade de um aumento em torno de 10% na margem de contribuição da empresa quando utilizado um mix de produtos encontrado pela técnica desenvolvida.

Palavras-chaves: Mix de Produto, Programação Estocástica, Grid Computacional

1. Introdução

Uma fábrica de filme plástico polipropileno bi-orientado (BOPP), para se manter competitiva, tem que ser capaz de produzir algumas centenas de produtos, variando em gramatura, coloração e corte de modo a atender novas exigências do mercado consumidor. Maior variedade de mix de produtos implica em aumento da complexidade da produção pelos *setups* envolvidos (NEOH, 2010). Como as decisões de mix afetam tanto a eficiência quanto a produtividade da manufatura, torna-se importante a adoção de técnicas de otimização no planejamento de produção. Contribui para isto, o fato do processo de fabricação de BOPP produzir rejeitos estocásticos ao longo do seu processo produtivo, nas etapas de extrusão e corte. Este trabalho apresenta uma técnica para a análise do problema Mix de Produto Estocástico, buscando maximizar as margens de contribuição em uma empresa fabricante de BOPP.

A técnica desenvolvida foi aplicada à uma empresa com um portfólio composto por mais de 200 produtos diferentes, distribuídos em três plantas localizadas em dois países distintos, cada uma com duas linhas de produção. A maior parte dos seus produtos é vendida para a indústria de embalagens alimentícias desses países e também para o mercado de exportação. Considerando suas seis linhas de produção e os três mercados consumidores possíveis, o problema de programação inteira mista (MIP) utilizado para a análise da alocação produto-linha tem em torno de 2.500 variáveis e 3.600 restrições.

O problema de mix enfrentado demanda a adoção de coeficientes estocásticos em razão da produção de rejeitos. Para isto, utilizou-se técnicas de programação estocástica (BIRGE & LOUVEAUX, 1997). Uma série de experimentos de Monte Carlo (METROPOLIS, 1949) foram gerados para se estimar uma solução ótima, utilizada para maximizar a margem de contribuição (SHAPIRO, 2008). Em cada experimento, configurações dos rejeitos dos produtos nas linhas de produção foram sorteadas. Cada configuração gerou um problema de MIP que foi resolvido para a determinação da contribuição máxima relativa a cada alocação dos produtos às linhas. As melhores alocações de produtos-linha foram selecionadas entre as configurações randomizadas para se encontrar solução viável com maior verossimilhança.

Para a solução de todos os problemas de MIP gerados pela randomização foi utilizada uma malha computacional distribuída com mais de 1200 processadores mantida pelo projeto colaborativo EELA-2 - E-science grid facility for Europe and Latin America (CARVALHO, 2011). O uso dessa infraestrutura computacional possibilitou a execução de 50.000 experimentos em 6 horas de processamento por experimento. O esforço computacional é equivalente a computação executada por um computador pessoal por 16 dias.

A análise dos diversos experimentos executados indicou a possibilidade de um aumento em torno de 10% na margem de contribuição da empresa quando utilizado um mix de produtos encontrado pela técnica desenvolvida.

Este trabalho está organizado da seguinte maneira: na seção 2 é apresentado o conceito de Mix de Produto e sua importância para indústrias. Na seção 3 discute-se a metodologia utilizada na pesquisa e desenvolvimento de uma solução específica para o problema da fabricante de plásticos em estudo. Na seção 4 são fornecidos alguns dados da empresa e seus produtos. As seções 5 e 6 referem-se ao desenvolvimento do modelo matemático utilizado para efetuar a simulação da operação da empresa e a implementação computacional deste modelo na infraestrutura do projeto EELA-2, respectivamente. Na seção 7 encontram-se os

resultados obtidos e uma breve discussão dos seus impactos. A seção 8 contém a conclusão do estudo e uma reflexão dos autores.

2. O problema de mix de produto

Mix de Produto envolve um processo de tomada de decisão no qual se objetiva maximizar uma função de lucro (em geral, representada pela margem de contribuição), atribuindo-se alocações de capacidades a um conjunto de produtos, considerando as limitações de produção das empresas e a demanda prevista pelos itens (CHUNG, 2005;NEOH, 2010). É um conceito bastante conhecido na área de gestão de operações. Um gestor, ao determinar seu mix de produtos, busca encontrar a forma mais lucrativa de produzir e comercializar bens através do uso racional dos recursos produtivos. O termo abrange desde a formação de um portfólio a ser oferecido aos clientes, no qual nem sempre mais é melhor, até a determinação da forma mais rentável de fabricar os produtos. Porque o aumento da quantidade de produtos ofertados por uma empresa reduz as economias de escala na produção especializada de poucos bens, trazendo o *trade-off* entre variedade de produtos e economias de escala, nem sempre um aumento na quantidade de produtos ofertados trará um aumento de lucros para a empresa, como muitas vezes é esperado pelo setor de marketing.

O desenvolvimento de uma linha de produtos consiste em duas etapas: (a) identificar o portfólio a ser adotado, baseado nas necessidades e expectativas dos clientes, e (b) avaliação e seleção do portfólio, que consiste em encontrar a forma mais lucrativa de alocar recursos escassos para a fabricação dos produtos (LI e AZARM, 2002). Essas etapas compõem o conceito de Mix de Produto. O presente trabalho estuda a configuração ideal para a alocação de recursos em uma empresa de plásticos, apresentada na seção 4. O leitor que se interessar por identificação de portfólio encontrará uma discussão importante em Jiao e Zhang (2005), além de muitas referências sobre o tema.

Pode-se pensar no Mix de Produto como um conjunto de decisões que buscam determinar qual configuração de produtos em suas linhas de produção trará maior retorno, dado que a empresa possuiu mais de uma linha de produção capaz de fabricar determinados produtos. Resumindo, em qual linha de produção cada bem deve ser fabricado de forma que a empresa alcance o maior retorno possível. Esta preocupação é enfrentada semanalmente e por muitos gerentes que, muitas vezes, fazem uso de *softwares* gerenciais genéricos, que não levam em conta as especificidades enfrentadas pela empresa, para auxiliar na análise deste tipo de problema e subsequente tomada de decisão.

Tradicionalmente o problema de mix é resolvido com o uso de técnicas de programação linear ou mista. Contudo, acredita-se que outras abordagens podem levar a melhores resultados. Neste trabalho serão utilizados conceitos de programação estocástica por ser uma técnica mais robusta para a solução de problemas permeados por incertezas. Programação estocástica é utilizada quando enfrenta-se um problema em que alguns dos parâmetros só se tornam conhecidos durante a ocorrência do evento. Na literatura podem ser encontrados diferentes métodos para a resolução de problemas estocásticos: modelos que utilizam recurso, modelos com restrições probabilísticas e ainda modelos de amostragem externa. Estamos interessados nesse último, que consiste em, a partir de probabilidades conhecidas, gerar um número de cenários suficientemente grande para que seja considerado representativo do universo de soluções.

3. Metodologia

Ao longo dos últimos anos a utilização de modelos quantitativos para estudar o funcionamento das empresas vem se difundindo cada vez mais. Segundo Bertrand e Fransoo

(2002), o uso de modelagem matemática na área de gestão de operações evoluiu, deixando de ser apenas uma forma de resolver problemas do dia-a-dia das empresas e passou a ser usada principalmente para o desenvolvimento de conhecimento científico. Contudo, este processo fez com que perdesse seu caráter empírico ao longo dessa evolução, que durou cerca de 30 anos. Agora se observa, mais que nunca, a necessidade de conciliar estas duas características da modelagem matemática como forma de desenvolver conhecimento científico e soluções para problemas reais de gestão de operações.

Modelos quantitativos são “baseados em um conjunto de variáveis que variam em um domínio específico, enquanto relações quantitativas e causais foram definidas entre essas variáveis” (BERTRAND e FRANSOO, 2002). A utilização desse tipo de construtos auxilia na compreensão de fenômenos observados nas operações de indústrias de bens e serviços, uma vez que descrevem – ou tentam descrever – a forma como os eventos ocorrem em sua totalidade ou em parte, permitindo não somente o estudo de eventos já ocorridos como também possíveis configurações futuras do sistema.

Neste trabalho foram utilizadas técnicas de modelagem matemática e simulação computacional para solucionar o problema de mix de produto de uma indústria de plásticos. As simulações foram realizadas com 50.000 instâncias do modelo e os resultados analisados através de técnica estatística de clusterização de dados.

Apesar de não haver consenso na literatura quanto à validade dos métodos de clusterização, optou-se por utilizar a técnica k-médias. Landau e Everitt (2003) exemplificaram o uso de diferentes técnicas, inclusive k-médias, para validar uma classificação de crânios tibetanos com bastante acurácia, defendendo a validade da utilização de aglomeração de dados. Já Sirmakessis et al. (2001) mostraram como a aglomeração de dados pode ser útil para a busca automática de informações em extensas bases de dados textuais, utilizando como exemplo um estudo da inovação e progresso científico e tecnológico na Europa através de bases de patentes.

Para produzir um relatório com informações capazes de auxiliar a gerência da empresa em estudo no planejamento da produção, foram preparados relatórios preliminares ao final das simulações. As informações nas quais os gerentes se mostraram mais interessados foram compiladas em um documento com gráficos e tabelas para facilitar sua compreensão. As principais informações procuradas são: (a) alocação dos produtos, (b) margem de contribuição total e (c) utilização da capacidade das linhas de produção.

4. O caso

A empresa estudada é uma fabricante de plásticos de Polipropileno bi-orientado (BOPP), que atua no mercado brasileiro e internacional. Seus produtos são fabricados em seis linhas de produção espalhadas por dois países da América Latina, compondo um portfólio com mais de 200 filmes distintos. Tem como principais clientes fabricantes de embalagens em vários países.

Os filmes BOPP servem de insumo para outras indústrias, sendo utilizados na fabricação de diversos tipos de embalagens flexíveis, inclusive embalagens de produtos alimentícios em contato direto por serem inertes e não tóxicos. Outras aplicações são a fabricação de rótulos e fitas adesivas, estando presentes em todas as partes do nosso dia-a-dia: em embalagens de biscoitos, revestimento interno das caixas de leite Longa Vida e muitos outros produtos. Apresentam como uma de suas vantagens o fato de serem totalmente recicláveis – estudos recentes mostram que mesmo as embalagens plásticas metalizadas de alimentos são totalmente recicláveis.

Uma linha de produção de BOPP é capaz de produzir uma ampla gama de produtos distintos, variando a gramatura, a transparência e o corte. Durante seu processo produtivo ocorrem perdas conhecidas como *scrap* (ou escória, ou seja, algo produzido que não atende às especificações de qualidade), principalmente nos processos de extrusão e corte mas também ocorrem durante os *setups* – isto porque os filmes são produzidos em processo contínuo e até mesmo os *setups* são efetuados com a linha de produção em funcionamento. Dessa forma, quanto mais próximas as características entre os produtos fabricados em determinada linha, menos rejeito será produzido no momento de transição de um produto para outro.

Os responsáveis pelo departamento de produção da empresa trabalham com um mix de produto que acreditam ser sub ótimo e procuraram consultores para tentar determinar o mix que poderia maximizar a margem de contribuição dos produtos comercializados pela empresa. Os produtos são separados por mercado consumidor, podendo ser interessante produzir um mesmo produto em plantas distintas para reduzir custos de transporte e alfandegários quando os clientes encontram-se em países diferentes. Quando tomados todos os itens comercializados pela empresa, identificados por mercado consumidor, tem-se um total de 215 produtos distintos e é preciso definir onde cada um deve ser produzido.

Sabe-se, por experiência, que no decorrer da produção o *scrap* ocorre de forma estocástica, o que dificulta a determinação do mix ótimo de produção. Como exemplo, foi realizada uma comparação entre os problemas determinístico e estocástico após concluída a modelagem, na qual identificou-se que o problema determinístico – simplificação do problema considerando o *scrap* como sendo fixo – representa um problema de programação mista que pode ser resolvido em menos de um minuto. Quando se considera o problema real – tomando o *scrap* como estocástico – e se utiliza a técnica de amostragem externa para resolução do problema, tem-se milhares de instâncias (cenários) que compõem a simulação da operação e cada uma dessas instâncias demora o mesmo tempo que o problema determinístico para ser resolvido.

A necessidade de efetuar simulações para determinar o mix de produto aumenta muito o tempo de solução do problema e inviabiliza que a simulação seja feita em apenas um computador. Explicando em dados, uma simulação preliminar para ajustes do modelo utilizou cerca de 16 dias de CPU – quando se fala em tempo de CPU, refere-se ao tempo que um único computador levaria para efetuar os cálculos – apenas para resolver o problema de mix, sem contabilizar o tempo decorrido durante a análise posterior dos dados obtidos.

As decisões de mix, diferentemente daquelas de sequenciamento de produção que têm caráter operacional, são de nível tático e devem ser revisadas em períodos que variam de indústria para indústria, mas em geral ocorrem a cada dois ou três meses. Durante o desenvolvimento do projeto, constatou-se que uma amostra de 50.000 instâncias de MIP deveria ser simulada e analisada para cada ciclo de estudos. Toda essa complexidade computacional tornaria proibitiva a revisão do mix em tempo hábil para que a empresa se preparasse para ajustar sua produção. A alternativa encontrada foi a utilização da infraestrutura de grid do projeto EELA-2. A disponibilidade de um grande número de computadores para efetuar a análise tornou possível a solução do problema de otimização de mix estocástico em tempo razoável para atender às necessidades da empresa.

5. Modelo

A utilização de modelos de simulação computacional apresenta algumas vantagens quando comparada com a experimentação direta de um sistema (PIDD, 1998). Essas vantagens residem em três aspectos: (a) custo, (b) risco e (c) tempo. A construção de modelos para estudar determinados fenômenos reduz os custos envolvidos pois dispensa, no caso de

indústrias, o uso ou aquisição de equipamentos produtivos de alto valor; quanto ao risco, preserva recursos materiais e humanos que seriam impactados pela alteração das condições normais de operação para realização de testes. Em relação ao tempo, o uso de modelos permite simular diversos cenários – e até mesmo anos e anos de operação – em alguns dias ou semanas, o que talvez fosse impossível em um processo de experimentação direta.

O modelo utilizado neste trabalho foi desenvolvido de acordo com descrições e observações do processo produtivo da empresa em estudo de forma que fosse capaz de representar o funcionamento das suas linhas de produção. Buscando reduzir os tempos de *setup* e níveis de scrap durante a troca de filmes, foram criadas restrições que forcem produtos com características similares a serem alocados nas mesmas linhas de produção. Essas restrições foram chamadas restrições de agrupamento. O modelo assim proposto possibilitou o sorteio de diferentes configurações de *scrap* para decisão do mix de produtos a ser implementado.

Maximizar:

$$\sum_i \sum_j \left(p_i - \frac{c_{ij}}{(1-s_{ij})} \right) + q_{ij}$$

Sujeito a:

$$\begin{aligned} \sum_i \frac{q_{ij}}{(1-s_{ij})} &\leq d_i, \forall j \\ \sum_i q_{ij} &= d_i, \forall i \\ q_{ij} &\geq K_{ij} y_{ij}, \forall i, j \\ q_{ij} &\leq d_i y_{ij}, \forall i, j \\ y_{kj} &= y_{mj}, \forall j \quad \text{se } m \text{ e } k \in \text{a um mesmo agrupamento} \\ q_{ij} &\geq 0 \\ y_{ij} &\in \{0, 1\} \end{aligned}$$

Onde:

- c_{ij} Custo do produto i na linha de produção j
- d_i Demanda do produto i
- K_{ij} Quantidade mínima do produto i na linha de produção j
- o_{ij} Output máximo do produto i na linha de produção j
- p_i Preço do produto i
- q_{ij} Quantidade do produto i feito na linha de produção j
- s_{ij} Scrap do produto i na linha de produção j
- T_j Tempo máximo disponível da linha de produção j
- y_{ij} Variável binária que indica se haverá produção do produto i na linha de produção j

6. Implementação computacional

As malhas ou *grid* computacionais são infraestruturas de recursos compartilhados (recursos de processamento e armazenamento de dados, *softwares*, instrumentos de leitura de dados, entre outros), que podem encontrar-se geograficamente dispersos, sendo estruturados em torno de Organizações Virtuais. Esse tipo de infraestrutura busca proporcionar um potencial computacional para a resolução de problemas que exigem uma grande quantidade de operações e podem ser particionadas em computações disjuntas.

Para analisar o problema enfrentado pela empresa foram efetuados experimentos computacionais de Monte Carlo, gerando milhares de instâncias do modelo com diferentes níveis de rejeito segundo as distribuições de probabilidades levantadas na séries históricas registradas pela a empresa. Para isso, foi criado um programa em C, capaz de randomizar cada uma das instâncias do modelo a partir de um arquivo de entrada que contém informações operacionais das linhas de produção, como custo, capacidade, preço de venda dos produtos, entre outros.

Para simular uma grande quantidade de cenários na infraestrutura computacional do projeto EELA-2, foram desenvolvidos programas que permitissem uma automatização das etapas da simulação, reduzindo o esforço ao executar as simulações que eram frequentes. Para tal, uma aplicação chamada de *Industry@Grid* foi desenvolvida para explorar a capacidade da infraestrutura computacional. Essa aplicação foi implementada em três módulos chamados de: (1) *ModelBuilder*, - responsável pela inicialização da malha computacional; (2) *Runner* – responsável pela solução dos experimentos gerados na inicialização; e (3) *Merger* – responsável pela consolidação dos dados obtidos nos experimentos. Após concluída a execução dos experimentos, seleciona-se a solução a ser implementada através da técnica de clusterização *k-médias*, que permite dispor as soluções em grupos utilizando uma medida de similaridade entre elas. Nas seções seguintes é apresentada uma descrição detalhada de cada módulo da aplicação.

6.1. ModelBuilder

O *ModelBuilder* prepara o ambiente para que as simulações sejam efetuadas. Com os dados relativos aos produtos, linhas, *scraps*, etc, é executado um programa na malha computacional que gera os problemas MIP e os agrupa em lotes para serem resolvidos. Devido a natureza distribuída da infraestrutura, réplicas dos dados são distribuídas em partes diferentes da malha para se minimizar os tempos de transmissão dos dados durante a execução do módulo seguinte. No EELA-2, a malha era composta por 28 centros de recursos (CR) computacionais, espalhados em instituições na América Latina e Europa (CARVALHO, 2011). Cada CR apresenta também um computador dedicado ao armazenamento temporário de dados (elementos de armazenamento - EA), que foi utilizado para o depósito das réplicas. Esse armazenamento *local* aumenta a eficiência do uso da infraestrutura.

6.2. Runner

O *Runner* é um módulo responsável pelo controle da execução dos lotes criados no passo anterior. Depois de agrupados, uma tarefa era sequenciada para a execução na infraestrutura para cada lote de experimentos existente. Além da escolha do melhor CR para a execução, o *Runner* era responsável pelo controle de falhas e resubmissão. Por exemplo, caso sejam criadas 50,000 instâncias e o usuário determine que sejam resolvidos 200 experimentos em cada lote, o Runner as enviará 250 tarefas para computadores localizados nos 28 CRs. Esses computadores acessam os lotes se utilizando das réplicas locais que contém uma lista com os experimentos que devem ser resolvidos., juntamente com os endereços dos EAs que contém as réplicas e o *software* de otimização – GLPK¹. No final de cada tarefa, o resultado dos experimentos é transferido para um EA do CR do CEFET/RJ, localizado no Rio de Janeiro.

6.3. Merger

O *Merger* consolida a informação da execução de todos os experimentos armazenados no EA do CEFET/RJ, gerando um arquivo com todas as soluções dos problemas de MIP relativas a

¹ disponível em <http://www.gnu.org/software/glpk/>

todos experimentos. No caso do exemplo com 50000 instâncias, uma matriz com 50000 soluções é gerado. Essa matriz é transferida para fora da malha computacional para ser efetuada a análise dos resultados.

6.4. K-médias

De posse dos arquivos de resultados, a simulação é concluída e resta efetuar a análise dos dados para determinar qual mix de produtos a empresa deve adotar ao buscar maximizar sua margem de contribuição total. Para tal, o método de k -médias foi utilizado. Esse método foi proposto inicialmente por Macqueen (1967) e apresenta várias aplicações, entre elas separar os objetos em clusters segundo uma medida de distância ou similaridade entre eles. Objetos podem ser representados por vetores de dimensão d , representados por $X = [x_1; x_2; \dots; x_n]$, que serão distribuídos em k clusters, com $k < n$, $S = \{s_1; s_2; \dots; s_k\}$ de forma a minimizar a soma dos quadrados das distâncias entre os objetos de cada cluster:

$$\text{Minimizar: } \sum_{i=1}^k \sum_{x_j \in S_i} \|x_j - \mu_i\|^2$$

onde μ_i é a média dos pontos pertencentes a S_i . O algoritmo proposto por Lloyd (1982) consiste na execução de três passos:

- Tomar, ao acaso, um conjunto de k objetos e atribuir cada um deles como a média do cluster S_i .
- Adicionar cada objeto ao cluster com a média mais próxima.
- Recalcular as médias μ_i de cada cluster.

O algoritmo repete os passos a e b até convergir, ou seja, até que nenhum objeto mude de cluster.

Do cluster mais representativo, aquele com o maior número de soluções, retira-se a solução mais próxima da média, por ser uma solução viável e considerada como representativa do conjunto de soluções ao qual pertence.

7. Resultados obtidos

O principal resultado encontrado é o mix de produto que maximiza a margem de contribuição para uma dada configuração de *scrap*. Este mix de produto leva dois resultados importantes: (a) margem de contribuição total e (b) utilização percentual das linhas de produção.

A solução que apresenta a configuração do mix é essencial para a operação da empresa. É ela que determinará qual produto deverá ser fabricado em cada uma das linhas de produção. Antes de ser implementada, contudo, a solução é revista pelos responsáveis pela produção, visto que alguns ajustes podem ser necessários. Entre os fatores que podem influenciar na mudança do mix final de produtos está o fato de que algumas plantas têm pouca experiência em produzir determinado produto, e a implementação causaria um custo de mudança que não é quantificado no modelo.

O estudo dos resultados das simulações permitiu a compreensão de como os níveis de *scrap* influenciam na operação e no resultado da empresa. Instâncias com níveis elevados de rejeito apresentam níveis mais baixos de margem não só pelo aumento de custo de produção sem aumento nas vendas, mas também porque alguns produtos precisam ser realocados para atenderem às restrições de capacidade das linhas de produção.

7.1. Alocação dos Produtos

Analisando-se, em conjunto, os resultados de todas as 50.000 instâncias da simulação, busque-se avaliar as mudanças na alocação dos produtos entre as diversas soluções. Quando um produto aparece na mesma linha de produção em pelo menos 95% das vezes, julga-se que pode ser retirado da análise, já que a linha onde deve ser produzido independe da variação das condições operacionais – principalmente quanto aos níveis de *scrap*. No caso da empresa de plásticos, 69 dos 215 produtos encaixam-se nesse caso, o que representa 32% do total, reduzindo a incerteza enfrentada pela empresa em relação à fabricação dos seus produtos.

É importante ressaltar que o mix de produtos otimizado, com validade matemática e estatística, é representado pela solução mais próxima da média do cluster principal e, uma vez feita qualquer modificação local, o resultado global poderá ser alterado. Essas modificações devem ser evitadas, pois podem causar a violação de uma ou mais restrições do modelo. No entanto, caso seja necessária alguma modificação por motivos específicos, se alguma alocação não puder ser implementada, as informações sobre os produtos que variam e as linhas em que mais aparecem são úteis para avaliar alternativas. Nesse caso, o tomador de decisão pode ter uma indicação de qual linha deve produzir determinado produto, de acordo com a frequência com que aparece em determinadas linhas.

7.2. Utilização da Capacidade Produtiva

A capacidade das plantas foi calculada segundo o número de horas disponíveis para a produção: as linhas operam 365 dias por ano, 24 horas por dia, menos tempo de paradas programadas e o tempo médio de *setup*. Esses tempos foram fornecidos por funcionários da empresa, baseado em dados dos anos anteriores. Após descontados, chegou-se à disponibilidade anual de 8094 horas para as linhas de produção.

A Figura 1 ilustra a comparação entre a capacidade das linhas em toneladas. Essa análise foi realizada dividindo-se a disponibilidade, em horas, pelo *output* médio de cada linha e o menor valor encontrado foi utilizado como base para parametrizar as capacidades das demais linhas. Dessa forma, ficam claras as diferenças de capacidade em toneladas, com algumas linhas apresentando capacidade maior que outras, em função da tecnologia presente em suas instalações. É esperado que as linhas com maior capacidade sejam priorizadas pelo modelo de simulação, uma vez que estas apresentam um desempenho superior, com custo e geração média de *scrap* inferiores.




Figura 1 - Capacidade comparada das linhas de produção

A partir dos resultados de todas as instâncias é possível encontrar uma utilização média da capacidade de cada uma das linhas. Essa análise é importante, pois pode facilitar tomadas de decisão estratégicas de médio e longo prazo como a desativação de linhas, investimentos em novas tecnologias e a instalação de novas linhas. A Figura 2 apresenta a utilização das seis linhas de produção para a solução escolhida. Ressalta-se o fato de que, como esperado – de acordo com a análise da Figura 1 – a linha C1 foi a que apresentou menor utilização de capacidade.

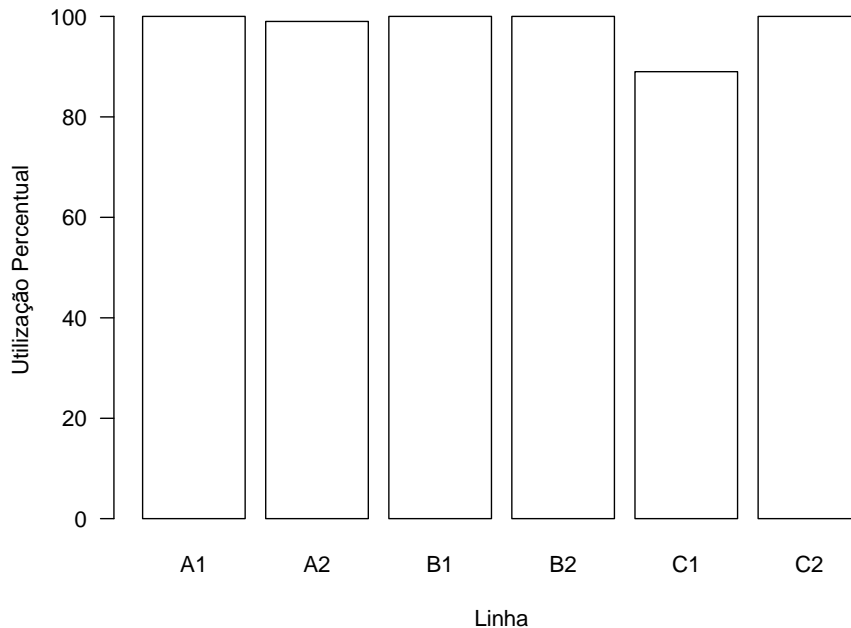


Figura 2 - Utilização média da capacidade das linhas

Outra questão relevante é o fato de quase todas as linhas estarem com a sua capacidade próxima ao máximo. Essa informação é coerente com a estratégia adotada pela empresa, buscando utilizar ao máximo sua capacidade instalada devido ao alto custo de instalação e manutenção de suas linhas. É importante ressaltar que, caso o mix de produtos utilizado anteriormente fosse mantido, haveria estouro de capacidade em algumas linhas, com todas as plantas funcionando no máximo de suas capacidades, devido a flutuações de demanda e níveis de *scrap*. Os ganhos com a implementação do mix de produtos não estão restritos ao aumento direto na margem de contribuição, mas envolvem o fato de haver uma liberação na capacidade instalada. Estima-se que o ganho financeiro que pode ser alcançado com a utilização das horas disponíveis para aumento de produção está em torno de 2% a 3% da margem calculada para o mix utilizado anteriormente.

As simulações também podem auxiliar o planejamento da expansão da capacidade. A ferramenta permite inferir se a capacidade atual é suficiente para atender uma dada demanda com vários níveis de *scrap*. A partir de um certo ponto, parte das soluções do modelo serão inviáveis, indicando que a demanda é superior à capacidade. Monitorando esse indicador, a empresa pode definir, o momento – nível de demanda – em que deverá realizar os investimentos em expansão de capacidade.

7.3. Margem de Contribuição

A margem de contribuição encontrada varia de acordo com a alocação dos produtos. A Figura 3 é um histograma da margem de distribuição encontrada na simulação com 50.000 instâncias do modelo. O eixo x, que representa a margem, foi parametrizado em relação à margem de contribuição encontrada para a configuração de mix anterior ao modelo. Observa-se, então, que o modelo apresenta uma solução superior a anterior em 98,37% das vezes. Apesar do potencial de aumento ser de até 23,86%, pelas características da distribuição normal, podemos afirmar com 95% de chance que a margem de contribuição estará entre 100,92% e 115,07%.




Figura 3 - Histograma da Margem de Contribuição

Para a solução escolhida, a margem de contribuição encontrada apresenta um aumento de 5%. Somado ao aumento que pode ser alcançado com a utilização da capacidade ociosa da linha C1 (2 a 3%) e à economia esperada com a redução dos tempos de *setup* pela dedicação das linhas de produção, espera-se alcançar um aumento em torno de 10%.

8. Conclusão

A abordagem utilizada para a resolução do problema de mix da empresa em estudo trouxe resultados bastante positivos. Além do aumento observado na margem de contribuição, ressalta-se a redução da utilização da capacidade das linhas de produção. Isso se deve, em parte, a uma maior especialização das linhas, alcançada com a utilização dos agrupamentos, que ainda traz benefícios não observados pelo modelo, como redução dos tempos de *setup* e *scrap* durante a troca de produtos. O modelo, aliado à simulação computacional, mostrou-se uma ferramenta capaz de auxiliar no planejamento de gestão da capacidade produtiva, podendo ser utilizado para avaliar diferentes níveis de demanda e identificar o momento em que investimentos devem ser realizados para melhorar o desempenho das linhas ou até mesmo a instalação de uma nova linha de produção.

Referências

- BERTRAND, J. W. M. & FRANSOO, J. C.** *Operations management research methodologies using quantitative modeling*. International Journal of Operations & Production Management, v. 22, n. 2, p. 241–264, 2002.
- BIRGE, J.; LOUVEAUX, F.** *Introduction to Stochastic Programming*. Springer Verlag, 1997.
- CARVALHO, D. et al.** *e-Infrastructures for e-Science: A Global View*. Journal of Grid Computing. Netherlands: Springer, DOI: 10.1007/s10723-011-9187-y, pre-print, 2011.
- JIAO, J. & ZHANG, Y.** *Product portfolio identification based on association rule mining*. Computer-Aided Design, v. 37, n. 2, p. 149–172, 2005.
- LANDAU, S. & EVERITT, B. S.** *A Handbook of Statistical Analyses Using SPSS*. [S.l.]: Chapman and Hall/CRC, 2003.

LI, H. & AZARM, S. *An Approach for Product Line Design Selection Under Uncertainty and Competition.* Journal of Mechanical Design, ASME-AMER SOC MECHANICAL ENG, v. 124, n. 3, p. 385–392, 2002.

LLOYD, S. P. *Least squares quantization in PCM.* IEEE Transactions on Information Theory, v. 28, n. 2, p. 129–137, 1982.

MACQUEEN, J. *Some Methods for Classification and Analysis of Multivariate Observations.* In: Le Cam, L. M.; NEYMAN, J. (Ed.). Proceedings of the fifth Berkeley Symposium on Mathematical Statistics and Probability. [S.l.: s.n.], p. 281–297, 1967.

METROPOLIS, N.; ULAM, S. *The Monte Carlo Method.* Journal of the American Statistical Association (American Statistical Association) v. 44 n. 247 p.335–341, 1949.

NEOH, SC. et al. *A Layered-Encoding Cascade Optimization Approach to Product-Mix Planning High-Mix-Low-Volume Manufacturing.* IEEE Transactions on Systems, Man, and Cybernetics—Part A: Systems and Humans, v. 40, n. 1, p. 133-146, 2010.

PIDD, M. *Computer Simulation in Management Science.* 4 ed. New York: John Wiley & Sons, 1998.

SIRMAKESSIS, S. et al. *STING: Evaluation of Scientific & Technological Innovation and Progress in Europe Through Patents in: 1st STING User-Focus Group Meeting.* Lausanne: [s.n.], 2001.

SHAPIRO, A.. *Stochastic programming approach to optimization under uncertainty.* Mathematical Programming Series B. V. 112 p. 183-220, 2008.