PREVISÃO DE DEMANDA E SIMULAÇÃO COMPUTACIONAL NAS EMPRESAS DE GESTÃO CONSERVADORA: ESTUDO DE CASO

Alexandre Magno Castañon Guimarães
Pontifícia Universidade Católica do Rio de Janeiro
Departamento de Engenharia Industrial
Rua Marquês de São Vicente, 225, Gávea, CEP 2453-9001, Rio de Janeiro, RJ
alexcastanon@skydome.net

Madiagne Diallo
Pontifícia Universidade Católica do Rio de Janeiro
Departamento de Engenharia Industrial
Rua Marquês de São Vicente, 225, Gávea, CEP 2453-9001, Rio de Janeiro, RJ
diallo@puc-rio.br

RESUMO
Este artigo apresenta um Estudo de Caso que aborda o uso da Previsão de Demanda e Simulação Computacional em uma unidade produtiva com administração de característica familiar e que não adota as modernas técnicas propostas por especialistas para a gestão da cadeia de suprimento. Para isto, uma metodologia de tratamento de dados que aumentou a precisão das Previsões foi proposta, e a partir dos dados obtidos foi possível analisar o desempenho dos fluxos dos processos simulados, o que permitiu auxiliar na gestão dos recursos, levando-se em conta principalmente a variabilidade da demanda e as incertezas dos mercados. Nessas análises foram utilizados os softwares Statgraphics Centurion e Arena para elaborar, respectivamente, os modelos de previsão de demanda e de simulação computacional.
PALAVRAS-CHAVES: Previsão de Demanda, Séries Temporais, Simulação Computacional.

ABSTRACT
This paper aims to show a case of Demand Forecast and Computer Simulation techniques carried out in a manufacturing plant with family administration feature that does not use the modern techniques proposed by Supply Chain management experts. In order to develop the study, a new method was proposed which resulted in the improvement of the demand forecast accuracy. With the forecasted data, it was possible to analyze the performance of the simulated manufacture flows. Such procedures improved the management of resources while the demand variability and the uncertainties of markets were considered. The Statgraphics Centurion and Arena softwares were used in order to developed, respectively, models for Demand Forecast and Computer Simulation for the study proposed.
KEYWORD: Demand Forecasting; Time Series Computer Simulation.

1. Introdução

O mercado consumidor tem se mostrado cada vez mais exigente, principalmente no que tange à qualidade dos serviços, produtos e redução dos preços. Nesse cenário percebe-se uma crescente competitividade nos ambientes de negócio, o que obriga as empresas a empreenderem esforços contínuos para a modernização e a buscarem soluções inovadoras. Essas ações têm por objetivo garantir a sustentabilidade do atendimento às necessidades dos clientes, o que exige uma gestão com visão sistêmica da cadeia de suprimentos. De uma maneira geral, as empresas estão cada vez mais conscientes de que a integração e o gerenciamento dos processos de negócios-chave entre os membros dessa cadeia são fatores que determinam o sucesso final das organizações.

Nesse contexto, as empresas que exercem uma administração familiar com uma gestão patriarcal, empírica e conservadora ou que exercem uma administração com característica similar têm sido motivo de preocupação uma vez que a grande maioria pode estar sujeita a estagnação ou até mesmo ao fracasso já que atualmente o uso da tecnologia faz diferença.

O alto grau de competitividade nos ambientes de negócio carece da capacidade de tomar decisões rápidas e precisas. A eficácia da tomada de decisão é proporcional aos dados disponíveis e da habilidade do tomador de decisão em conseguir nesses as informações significativas.

O planejamento e a programação de produção são métodos importantes para otimizar o sistema de produção, sendo esse um dos problemas enfrentados pelas empresas, exigindo o uso de novas tecnologias para se obter um desempenho operacional cada vez mais eficiente. Nesse cenário, as empresas buscam por novas ferramentas de forma a se manterem mais competitivas e a conquistarem novos mercados. Desse modo, constitui-se um desafio, a tarefa de decidir, dentre as diversas opções disponíveis, aquelas que melhor atendam aos objetivos, estejam eles relacionados, como por exemplo, à minimização de custos, a melhoria de qualidade, a maximização de lucros, a otimização de layout e da alocação dos recursos, entre outros. Dentre as ferramentas adequadas existentes no mercado, pode ser citada a previsão de demanda e a simulação computacional.

A ferramenta previsão de demanda é muito útil na operacionalização do gerenciamento da produção, já que ela permite estabelecer, através da análise dos dados, os volumes de produção de modo a garantir um melhor desempenho na estratégia de planejamento e programação de produção, como por exemplo, gestão de estoques e elaboração de planos agregados de produção. Dessa forma, as tomadas de decisão tendem a ser mais rápidas e precisas resultando numa empresa mais ágil, com menos perdas e mais competitiva.

A simulação computacional é uma ferramenta capaz de reproduzir os diversos cenários e estimar os respectivos resultados. Uma análise feita através do desempenho dos fluxos de processos simulados permite auxiliar a gestão dos recursos e estimar os ganhos de novas alternativas, principalmente considerando a variabilidade da demanda e as incertezas dos mercados.

2. Previsão de Demanda

A importância da previsão de demanda pode ser evidenciada pelo seu uso nas diversas áreas de gestão organizacional (financeira, recursos humanos e de vendas). Tais previsões são também essenciais na operacionalização de diversos aspectos do gerenciamento da produção, como a identificação de oportunidade de novos mercados, antecipação de demandas futuras, programação da produção mais eficiente e gestão de estoques. Além disso, o uso das previsões ajuda a estruturar as organizações visando dimensionar a quantidade de bens ou serviços que irão produzir de modo que possam prever e atender à demanda proveniente do mercado consumidor (Sanders, et al 2003; Werner & Ribeiro, 2006).

De acordo com Bowersox & Closs (2007) existem três tipos de técnicas: qualitativa, causal e série temporal. A técnica baseada em série temporal modela matematicamente a

demanda futura, através do uso de métodos estatísticos, relacionando os dados históricos do próprio produto com o tempo. De acordo com o autor, esta técnica assume que o futuro é similar ao passado, e por esta razão considera a premissa que os padrões de demanda existentes continuarão no futuro. Segundo Wanke *et al.* (2006) existem mais de 60 modelos de técnicas quantitativas baseadas em séries temporais com variados graus de sofisticação, entretanto isto nem sempre garante resultados expressivamente melhores do que os alcançados com os modelos mais simples.

De acordo com Wanke *et al*. (2006), existem diversos métodos de cálculo para a acurácia da previsão destacando-se: (a) Método *Mean Absolute Deviation (MAD)* que permite avaliar o erro da previsão sem a influência dos sinais, desta forma um erro negativo não anula um erro positivo; (b) Método *Mean Percentual Error (MPE)* que verifica se o modelo de previsão possui alguma tendência, ou seja, se os valores estimados da previsão estão sistematicamente acima ou abaixo das demandas; (c) Método *Mean Absolute Percentual Error (MAPE)* cujo objetivo é avaliar a grandeza do erro em relação à série temporal. O cálculo é feito em percentual; e (d) Método *Mean Squared Error (MSE)* que permite estimar a variação do erro de uma previsão, elevando-se ao quadrado a média dos erros e dividindo o resultado pelo número de períodos. Um dos problemas deste método é que os valores que apresentam uma significativa discrepância em relação à média receberão grande significância, quando deveriam ser desconsiderados.

3. Simulação Computacional

A utilização da simulação computacional como apoio a tomada de decisão tem permitido analisar de forma sistêmica as unidades de negocio. Law & Kelton (2000) afirmam que a simulação tem como beneficio obter uma visão sistêmica do efeito que alterações locais podem produzir sobre o desempenho global de todo o sistema de produção. Modelos de simulação são construídos para dar suporte a decisões sobre investimentos em novas tecnologias, expansão da capacidade de produção, gerenciamento de materiais, recursos humanos e integração com os fornecedores, ou seja, através da simulação é possível estabelecer metas estratégicas de manufatura (McLean & Leong, 2001). Os trabalhos divulgados na literatura técnica constatam os diversos benefícios obtidos com o uso da Simulação Computacional. Dentre eles, destacam-se: (a) através dos modelos de simulação é possível estimar o que precisa ser melhorado e quando esta melhoria se faz necessária, facilitando, portanto, a tomada de decisões; (b) grandes idéias e melhorias podem ser obtidas através do uso da simulação computacional, já que a animação do processo facilita o entendimento dos gestores; (c) a simulação permite a possibilidade de validar se a decisão tomada é a melhor ou não; (d) a simulação reduz os gastos, o tempo e evita as interrupções inerentes a tradicional técnica de tentativa e erro (McClellan, 2004; Harrel et al., 2000).

Os pesquisadores Sandanayake, Y.G. *et al* (2008) destacaram que a simulação e a modelagem ajudam a visualizar, analisar e a otimizar os processos de produção complexos em um tempo razoável frente à complexidade do estudo e do investimento. Os autores citam, através de uma revisão da literatura, que a simulação e a modelagem não têm sido extensivamente aplicadas em ambientes de manufatura com just-in-time (JIT). Os autores utilizaram o *software* ProModel para modelar e simular os diversos cenários experimentais.

Um exemplo do uso da técnica de simulação em futuras instalações foi apresentado por Greasley, A. (2008). O autor desenvolveu e utilizou um modelo de simulação de evento discreto para estimar a área de estocagem necessária para uma instalação de manufatura no segmento têxtil. Além do estudo de caso o autor demonstra que a simulação de eventos discretos é um facilitador que pode fornecer uma compreensão qualitativa do comportamento do processo acima, além dos benefícios normais associados a esta técnica.

4. Estudo de Caso

As empresas familiares são formas predominantes em todo o mundo e ocupam uma parte tão grande da paisagem econômica e social que, muitas vezes, as pessoas sequer se dão conta disso (Dagnoni et al., 2007). A administração da empresa com característica familiar é considerada menos burocrática e impessoal, pois o acesso à cúpula administrativa é mais fácil, o que pode tornar as operações mais flexíveis e as decisões mais rápidas do que nas de capital aberto. No entanto, em razão de alguns traços do seu tipo social (espontâneo, extrovertido, indisciplinado, no que diz respeito à organização social e administrativa), o processo administrativo tende mais à improvisação do que ao planejamento, ou seja, as empresas acabam praticando aquilo que o seu "bom senso" considera adequado, decidindo por impulso, demonstrando um temor muito grande a mudar ou aceitar novas formas ou ferramentas de gestão (Grzybovski et al., 1998).

O Grupo onde o estudo de caso foi realizado atua na área de vedação e isolamento térmico e por questões de confidencialidade será chamado de BETA. A empresa fabrica seus produtos de forma integrada e verticalizada. A fábrica do Grupo BETA escolhida para aplicar a Previsão de Demanda e Simulação Computacional produz um único tipo de produto, denominado de Placa de Vedação, que é utilizado como elemento de vedação de fluidos em diversas aplicações, tais como flanges, cabeçote de motores, compressores entre outras. A unidade em estudo não faz uso de nenhum modelo de previsão de demanda. Outro ponto a ser ressaltado é que o Grupo BETA é deficiente de um processo estruturado de comunicação e de integração das informações entre os setores do sistema produtivo como compras, vendas, marketing, produção e demais setores, como também não é estruturado nos moldes do MRP, MRPII ou ERP.

4.1. Previsão de Demanda

Os dados de demanda utilizados nesse trabalho são oriundos da base de dados relativos às vendas de um período de 48 meses. A partir destes dados, uma estratificação para cada tipo de mercado foi feita de modo que os dados foram classificados por tipos de clientes/mercados semelhantes resultando em séries temporárias por grupo. Para exemplificar foram selecionados, dentre eles, três grupos. Por motivos estratégicos e de confidencialidade não serão revelados os nomes dos clientes/mercados, sendo adotada a seguinte nomenclatura: Mercados A, B e C.

Segundo Wanke *et al*. (2006) existem duas metodologias para selecionar o melhor modelo. A primeira forma estabelece um modelo através da avaliação da série e da aplicabilidade de cada modelo, já a segunda consiste na avaliação da precisão obtida com a aplicação de diversos modelos optando por aquele que apresentar o menor erro médio. Chopra & Meindl (2003) ressaltam que os erros da previsão possuem informações valiosas e devem ser analisados cuidadosamente, permitindo verificar a adequação dos modelos em uso ou propostos.

A análise de demanda de cada série temporal foi feita utilizando duas metodologias denominadas como "Método I" e "Método II". O *software Statgraphics Centurion* foi utilizado para o desenvolvimento desse estudo, pois permitiu avaliar os diversos tipos de modelos através da comparação dos erros. Dentre os modelos existentes no *software* foram selecionados os seguintes tipos: Média móvel (MM), Suavização Exponencial Simples (SES), Modelo de *Brown* (MB), Modelo de *Holt* (MH), Modelo de *Winter* (MW) e ARIMA. A validação dos modelos foi feita através da comparação das previsões dos quatro períodos posteriores.

O primeiro passo do Método I consiste em determinar o "modelo proposto" com base na premissa de seleção do melhor modelo através da avaliação dos erros médios MAPE e MAD, ou seja, o "modelo ótimo" será aquele cujos erros MAPE e MAD sejam mínimos simultaneamente. Caso essa premissa não seja conseguida, será considerado como ótimo o modelo que tiver o menor erro MAD, já que este permite avaliar o erro da previsão sem a influência dos sinais. Com o modelo ótimo, é estimada a previsão para o período seguinte e essa é comparada posteriormente com a demanda real. Essa seqüência foi demonstrada para quatro

períodos sucessivos, sendo que a série histórica utilizada para obter o modelo foi sempre atualizada com o dado da demanda real. A Figura 1 ilustra esta metodologia.

O Método II segue o mesmo procedimento do Método I, porém inclui a substituição dos pontos atípicos da série histórica pelos dados previstos no Método I. Entendem-se como pontos atípicos aqueles que distorcem o comportamento da série temporal, sendo ocasionados por variações do cenário econômico, alterações de preços nos produtos, falhas nas compras dos insumos, deficiência no planejamento de produção, antecipação ou postergação de pedidos por motivos estratégicos, entre outros. Neste trabalho foi considerado que um ponto atípico é aquele cuja razão entre o módulo da diferença da demanda real e a previsão pela demanda real seja maior ou igual a 0,2 (Equação 1). A Figura 1 ilustra esta metodologia.

Razão = |(Demanda Real - Previsão)| / (Demanda Real) ≥ 0,2 Equação (1)

Ao final, a comparação entre os Métodos foi feita visando avaliar a influência dos erros na previsão de demanda.

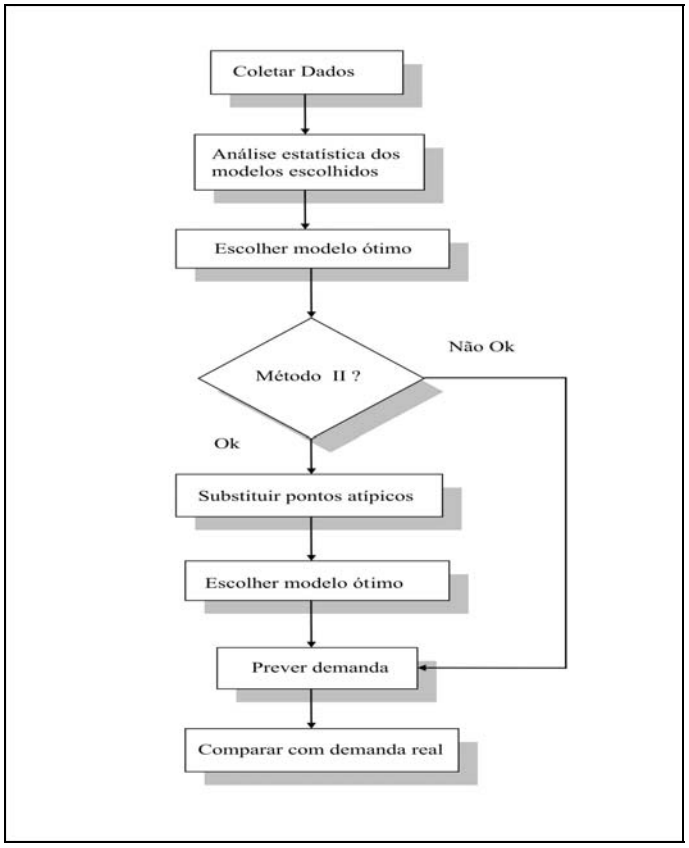

Figura 1- Descrição dos Métodos I e II

A Tabela 1 apresenta os resultados na aplicação dos Métodos I e II para o Mercado A. Os resultados demonstram que, independente do método aplicado, o modelo ARIMA foi sempre o que apresentou os menores erros MAD e MAPE. Este resultado está de acordo com o perfil da série temporal para esse Mercado, ou seja, a série não apresenta os componentes de tendência e nem de sazonalidade. Além desse resultado, outro fator observado foi à significativa redução nos erros MAD e MAPE para o Método II, o que permitiu aumentar a precisão da previsão. A demanda real esteve dentro do intervalo previsto pelo modelo II somente nos períodos 50 e 51 e ultrapassou o limite superior previsto para os períodos 49 e 52. De acordo com os especialistas, estas demandas atípicas ocorreram devido a dois fatores: (a) houve uma redução acentuada na demanda do período 48 por motivo de férias coletivas o que acarretou em um aumento significativo na demanda do período 49; e (b) ocorrência de sucessivas paradas para manutenção nas indústrias petroquímicas, o que resultou em uma considerável elevação da demanda no

período 52. Outra característica importante observada nesta avaliação foi que o Método II produziu sempre modelos com comportamento estacionário.

P	M	Modelo	Demanda Real	Previsão			Erro	
				médio	Min	Max	MAD	MAPE
49	I	ARIMA (1,1,1)	119150	86793	52981	120606	13275	14,75
	II	ARIMA(1,0,1) [a]		83617	62975	104260	7836	8,43
50	I	ARIMA(2,0,2) [a]	117427	85136	52985	117287	12757	14,1
	II	ARIMA(0,0,1) [a]		108630	86364	130896	8656	9,25
51	I	ARIMA(1,0,0) [a]	98777	99097	65217	132977	13853	15,4
	II	ARIMA(0,0,1) [a]		97490	75360	119621	8570	9,14
52	I	ARIMA(1,0,0) [a]	141213	94475	60960	127989	13579	15,1
	II	ARIMA(0,0,2) [a]		94129	72014	116243	8417	8,98

P: Período; M:Método; a: com constante.

Tabela 1- Previsão de Demanda para o mercado A – Métodos I e II

Os resultados apresentados na Tabela 2, relativos ao Mercado B, mostram que o Método I teve sempre como resultado o modelo ARIMA para todos os períodos estudados. Para o Método II, o modelo ARIMA, também foi o que melhor representou o comportamento da série temporal, embora no período 49, o método tenha apresentado o modelo de Média Móvel como o "modelo ótimo". No entanto, analisando os resultados obtidos para todos os modelos, observou-se que a minimização simultânea dos erros MAD e MAPE não ocorreu, o que levou o modelo de média móvel a ser escolhido por ter o menor MAD, conforme critério definido anteriormente. É importante ressaltar que neste caso o modelo ARIMA(2,1,2), apresentou o menor MAPE e o segundo menor MAD, porém, observa-se que o intervalo de previsão obtido com o modelo ARIMA(2,1,2) foi menor e levemente deslocado no limite inferior em relação ao modelo de Média Móvel, contribuindo para uma maior precisão na previsão.

P	M	Modelo	Demanda Real	Previsão			Erro	
				médio	Min	Max	MAD	MAPE
49	I	ARIMA (2,1,2)	58675	64102	29220	98983	13080	19,93
	II	MM c/ 2 termos		66990	44842	89138	7197	10,44
		ARIMA (2,1,2)		65370	44794	85945	7339	10,39
50	I	ARIMA (2,1,2)	53572	56209	21687	90730	13131	20,10
	II	ARIMA (0,2,2)		55006	32173	77838	6978	10,27
51	I	ARIMA (2,1,2)	57509	48034	14025	82043	12782	19,53
	II	ARIMA (0,2,2)		49696	27123	72270	6861	10,11
52	I	ARIMA (1,1,2)	65565	43842	10316	77369	13009	20,00
	II	ARIMA (0,2,2)		50150	27713	72587	6872	10,17

P: Período; M: Método.

Tabela 2 - Previsão de Demanda para o mercado B – Métodos I e II

Outro fator relevante na análise que justificam os modelos obtidos é que a série temporal do mercado B tem um comportamento não estacionário, como também ausência dos componentes de tendência e de sazonalidade. A não ocorrência de eventos especiais que alterassem o comportamento da demanda nos períodos estudados contribuiu para a adequação dos modelos de previsão adotados. Observa-se que os dados reais da demanda ficaram dentro do

intervalo de confiança de 95% da previsão em todos os períodos para os dois Métodos. Entretanto com a substituição dos pontos atípicos, o Método II apresentou uma significativa redução na amplitude dos erros MAD e MAPE, tendo como conseqüência uma maior precisão na previsão.

A Tabela 3 apresenta os modelos ótimos para o Mercado C obtidos pelos Métodos I e II e os seus respectivos erros e previsões. Diferente dos mercados anteriores, o modelo ARIMA não foi escolhido como o modelo ótimo para o Método I em nenhum período, ou seja, o modelo de Suavização Exponencial Simples foi o que melhor representou a série temporal visto que esta apresenta um forte comportamento aleatório. Com relação às previsões obtidas com este método, observa-se que a demanda real ultrapassou o limite superior do intervalo de confiança no período 51. Após a substituição dos pontos atípicos (Método II) observa-se que a demanda real ultrapassou o limite superior nos períodos 50 e 51 e inferior no período 52. Visando explicar o resultado, uma consulta ao especialista da área de mercado foi feita, e este informou que o comportamento atípico nestes períodos se deve ao fato de que a empresa anunciou que iria reajustar os preços no período 51. Este acontecimento fez com que o mercado desse segmento antecipasse os pedidos, tendo como conseqüência um aumento significativo nos períodos 50 e 51 e uma redução também significativa no período 52. Este resultado explica porque o modelo foi alterado de ARIMA para Amortecimento Exponencial Simples no período 52, ou seja, o novo modelo tentou reagir à demanda ocorrida no período 51, visto que o alfa adotado foi praticamente 1, ou seja, o modelo praticamente repetiu a demanda real do período 51 na previsão do período 52 (Tabela 3). Este fato ressalta a importância da integração entre as áreas e da parcela significativa da análise dos especialistas, já que a posse das informações no tempo real permite que possíveis ajustes sejam feitos de modo a obter maior precisão na previsão.

P	M	Modelo	Demanda Real	Previsão			Erro	
				médio	Min	Max	MAD	MAPE
49	I	SES (α: 0,1956)	63561	51362	1096	101629	15804	38,60
	II	ARIMA (0,1,2)		55945	42438	69452	4710	10,29
50	I	SES (α: 0,1956)	76277	53748	3880	103617	15730	38,21
	II	ARIMA (0,1,2)		60336	46832	73841	4767	10,31
51	I	SES (α: 0,2019)	116958	58359	8599	108119	15860	37,96
	II	ARIMA (0,1,2)		75457	61371	89543	5079	10,67
52	I	SES (α: 0,2488)	62703	74048	22275	125822	16646	37,93
	II	SES (α: 0,9999)		116954	99488	134419	5855	11,34

P: Período; M: Método

Tabela 3 - Previsão de Demanda para o mercado C – Métodos I e II

Conforme apresentados os resultados de cada série temporal, a obtenção de um modelo de previsão ótimo nem sempre implica na obtenção de uma previsão satisfatória da demanda para o mercado modelado. Alguns casos foram ressaltados, como os mercados A e C que apresentaram eventos especiais modificando o comportamento das séries no período correspondente ao horizonte de previsão, prejudicando assim a eficácia das previsões. Levando-se em consideração que esses eventos especiais eram do conhecimento dos especialistas, ressalta-se o fato da importância da integração entre as áreas e da parcela significativa da análise dos especialistas, já que a posse das informações no tempo real permite que possíveis ajustes sejam feitos de modo a obter maior precisão na previsão.

4.2. Simulação Computacional

A simulação Computacional foi feita através do *software* Arena para cada mercado utilizando a previsão de demanda do período 49 obtida pelo Método II. A modelagem proposta

para a fábrica Placa de Vedação foi feita para cada mercado separadamente. No estudo foram utilizados os dados históricos das médias e desvios padrões que são usados para programar toda a unidade, que já levam em consideração os dados relativos às fadigas mental e física, ineficiências, preparações, refeições e até mesmo as necessidades fisiológicas. A análise dos dados foi feita utilizando o *software Statgraphics Centurion* que sugeriu uma distribuição probabilística normal através dos testes *Chi–Squared* e *Shapiro–Wilk W* , conforme tabela 4.

Processo	Mercado A	Mercado B	Mercado C
Borracha	N(11,0.5)	N(11,0.5)	N(11,0.5)
Fibras	N(43,2)	N(43,2)	N(43,2)
Cargas	N(11,0.5)	N(11,0.5)	N(11,0.5)
Reatores	N(100,4)	N(100,4)	N(100,4)
Calandras	N(160,5)	N(260,6)	N(140,4)
Acabamento	N(8,0.2)	N(10,0.4)	N(8,0.2)

Tabela 4: Distribuições probabilísticas dos processos da unidade fabril em estudo

Mesmo assim foram feitas entrevistas com os especialistas dos processos (operadores e engenheiros) para se comparar e validar os dados. No entanto, por motivos de confidencialidade, esses dados não podem ser divulgados e, portanto foram corrigidos por um fator. Essa correção não alterou a proposta do estudo que é demonstrar as possíveis alternativas de cenários produtivos que podem ser obtidas com esta técnica, auxiliando aos gestores nas suas análises e tomadas de decisão. As atividades necessárias para o processamento do produto estão descritas na Figura 2.

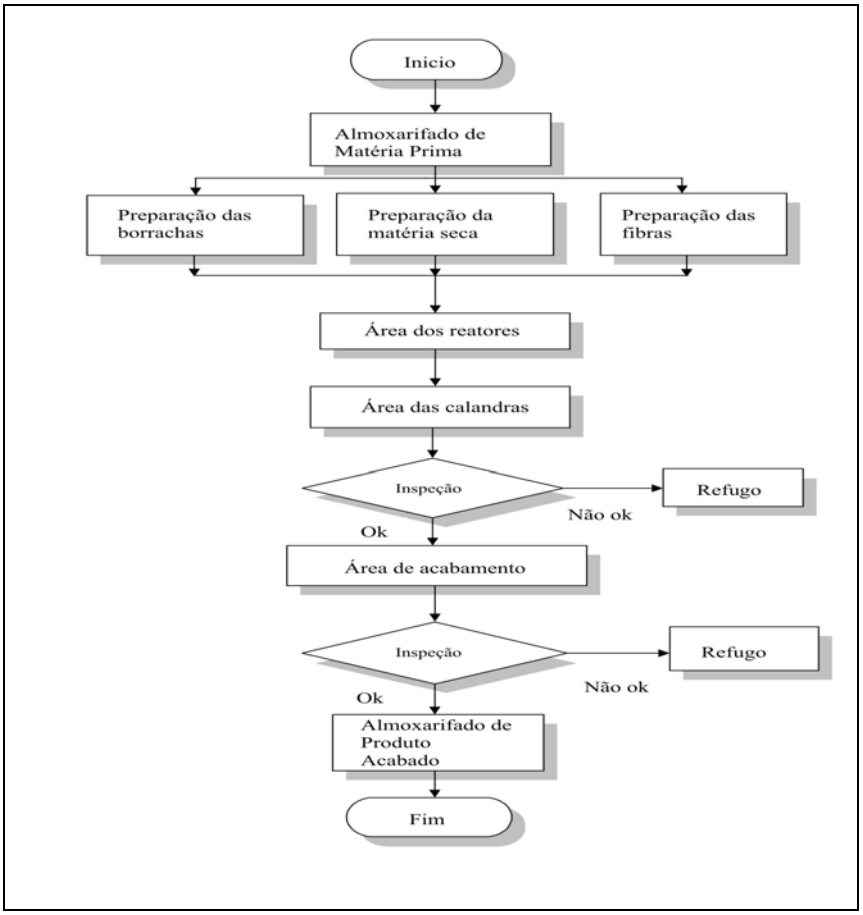

Figura 2 - Fluxograma do processo de fabricação da Placa de Vedação

A primeira etapa é a solicitação das matérias-primas ao almoxarifado, não sendo considerado no estudo o processo de compra e estocagem já que o abastecimento é de responsabilidade de outra unidade. Deste modo, foi considerado que o processo de abastecimento tem capacidade infinita, ou seja, sempre haverá matéria-prima disponível para uso. Em seguida, as matérias-primas são direcionadas para as áreas de processamento de borracha, matéria-seca e fibra, onde são elaborados os respectivos *kits*. A área dos reatores é o local onde se processam as misturas. O operador de mistura busca os kits de borracha, de matéria seca e de fibra e alimenta o reator conforme procedimentos de fabricação. Ao término do tempo de processamento, a mistura é descarregada em um carrinho e fica armazenada na própria área dos reatores. O transporte do carrinho da mistura da área dos reatores até a área de calandra é feito pelo operador de calandra. Nesta área ocorre à produção das folhas de Placa de Vedação que ficam armazenadas sobre mesas móveis, onde serão inspecionadas. O material classificado é então transportado para a área de acabamento pelos operadores de acabamento, enquanto que o material desclassificado segue para o refugo. Na área de acabamento realizam-se as atividades de corte, aplicação de antiaderente e impressão da logomarca. Ocorre também uma segunda inspeção onde o material desclassificado segue para o refugo e o classificado é transportado para o almoxarifado de produto acabado (APA) onde fica armazenado, para posterior embalagem de acordo com as solicitações dos pedidos.

A unidade em estudo funciona em 3 turnos de segunda a sábado. A manutenção preventiva é realizada sempre aos domingos, portanto não será considerada nesse estudo. Por motivos estratégicos e de confidencialidade, não será revelada a real capacidade produtiva instalada da unidade. Isto não compromete o estudo proposto, já que o objetivo é mostrar o potencial da aplicação da ferramenta de simulação computacional, propondo o melhor cenário dos recursos máquinas/operadores e fluxo do processo para atender a demanda prevista.

Para a modelagem proposta foram definidas: Entidades: borracha, matéria seca e fibra; Recursos: operadores de cada área, reatores e calandras; Filas: processos de borracha, matéria seca, fibra, reatores, calandras e acabamento.

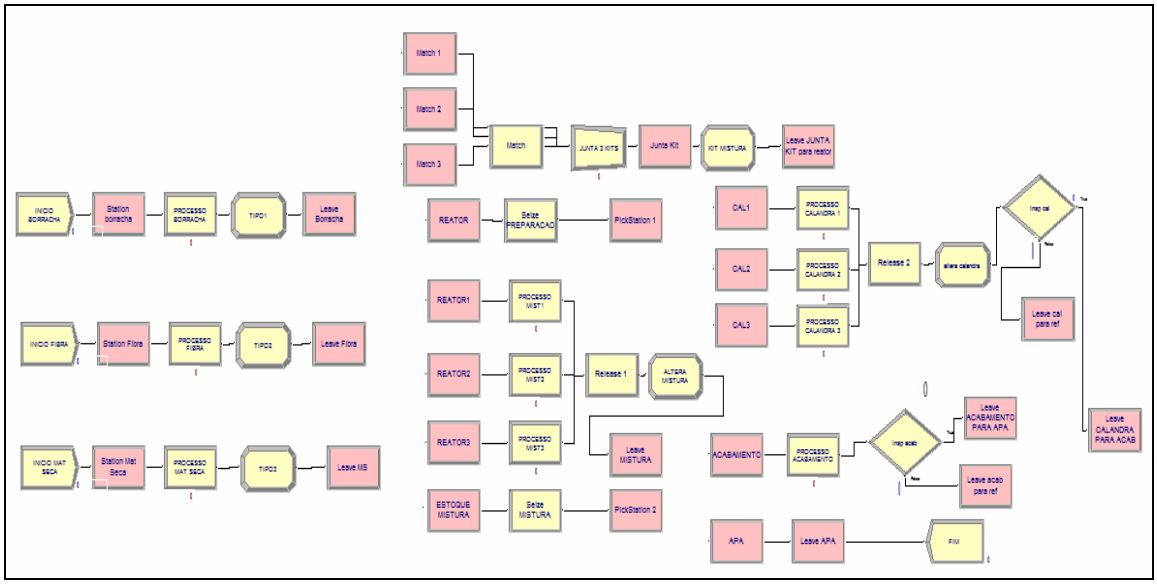

Figura 3: Lógica do processo da unidade Placa de Vedação

Os indicadores de desempenho utilizados para avaliar o melhor cenário dos recursos máquinas/operadores e fluxo do processo visando atender a demanda prevista foram: Tempo médio na fila (TF), ou seja, o tempo médio que uma entidade leva esperando na fila para ser atendida em um recurso; Utilização média do recurso (UR), expressada pela razão entre o tempo efetivamente gasto durante o processamento e o tempo total disponível; Total processado em cada recurso/processo (TMP): de borracha, de fibra, de matéria seca, dos reatores, das calandras,

do acabamento e o total processado que chegou ao final do sistema disponível para dar entrada no almoxarifado de produto acabado. Todos os tempos utilizados nessa modelagem estão em minutos.

A lógica da modelagem descrita acima esta representada na figura 3 pelo modelo de simulação do *software* Arena.

A animação da modelagem dos Recursos, Entidades, Processos, Filas e os Indicadores de Desempenho estão ilustrados na Figura 4. Considerando as análises feitas para os mercados foi possível obter através da simulação os tempos de ocupação de cada processo. As modelagens de cada mercado mostraram para cada processo as limitações e as ociosidades, assim como também as suas principais filas e suas utilizações, possibilitando identificar gargalos e desbalanceamentos da linha. Com essas informações é possível reagir com antecedência às variações das demandas propondo soluções que otimizem os recursos e atendam as necessidades de cada mercado. Pode-se verificar também que é possível otimizar a alocação dos operadores.

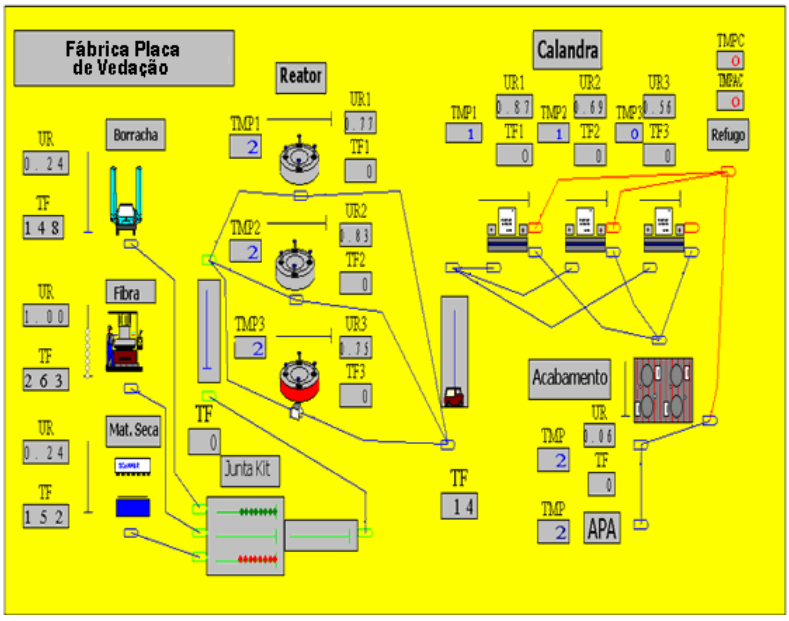

Figura 4- Representação ilustrativa da animação para a unidade de Placa de Vedação

A partir desses valores determinou-se a quantidade de processos necessários para atender a demanda no período 49, conforme apresenta a Tabela 5. Esses dados indicam uma ociosidade nos tempos de ocupação para as áreas de borracha, matéria seca e acabamento, com 3.30, 3.30 e 2.48 horas, respectivamente, ou seja, é necessário menos de um turno de ocupação. Tal desbalanceamento pode ser contornado melhorando a alocação dos operadores, por exemplo, os operadores do processo de borracha podem absorver as atividades do processo de matéria seca. No caso da área de acabamento, embora tenha apresentado somente um tempo de ocupação de 2.48 horas, não foi contemplado na modelagem o tempo destinado às atividades envolvendo o refugo, portanto manteve-se a equipe de quatro operadores.

Já para área de fibra observa-se que é necessário um tempo de ocupação de 38,64 horas, ou seja, esta área não será capaz de atender a demanda solicitada mesmo trabalhando em três turnos, portanto será necessário ter dois processos de fibra um com três e outro com dois turnos, totalizando cinco operadores. Outra opção seria manter três turnos e terceirizar a diferença para o atendimento da demanda prevista.

Utilizando a mesma análise para as áreas de reator e calandra, verifica-se que a área de reator precisa ter 4 processos operando em três turnos, portanto recomendam-se quatro operadores por turno. Na área de calandras necessita de sete processos operando em três turnos, o que sugere dois operadores por calandra por turno, totalizando quarenta e dois operadores.

Área	Tempo de ocupação (h)	Quantidade de Processos
Borracha	3,30	1
Matéria Seca	3,30	1
Fibra	38,64	2
Reator	90,24	4
Calandra	166,80	7
Acabamento	2,48	1

Tabela 5 - Tempo de ocupação e quantidade de processos para a demanda do período 49

Assim sendo, considerando a relação de operadores por processo já existentes na Unidade e a análise dos dados da Tabela 5 é possível apresentar uma proposta de alocação de operadores de modo a tentar otimizar a linha, conforme Tabela 6.

Área	Tempo ocupação (h)	Quantidade Processos	Nº turno	Nº operadores/ turno	Total de operadores
Borracha	3,30	1	1	2	2
Matéria Seca	3,30	1	1	0	0
Fibra	38,64	2	2,5	1	5
Reator	90,24	4	3	1	12
Calandra	166,80	7	3	2	42
Acabamento	2,48	1	1	4	4

Tabela 6: Estrutura proposta para atender a demanda do período 49

Outro fator a ser destacado é a possibilidade de a empresa saber antecipadamente qual a disponibilidade para fabricação dos produtos *make to stock* e, portanto escolher qual a melhor estratégia a ser adotada, através dos planejamentos de produção.

Outro beneficio observado com o uso da simulação computacional de grande proveito para a empresa, foi de que com a aplicação dos modelos propostos é possível obter uma visão sistêmica dos efeitos que alterações nos processos terão sobre o desempenho global dos fluxos de produção, possibilitando a criação de cenários futuros sem a necessidade de investimentos reais. Dessa forma, o tomador de decisão pode conhecer as conseqüências de suas ações, permitindo uma melhor avaliação dos sistemas logísticos e tendo como conseqüência uma maior eficiência na utilização dos recursos, na redução dos estoques intermediários e finais, menores custos operacionais, dentre outras.

5. Conclusão

Este artigo abordou o potencial da aplicação das ferramentas de Previsão de Demanda e Simulação Computacional como apoio à tomada de decisão em empresas conservadoras que exercem uma administração familiar ou com característica similar e que não adotam as modernas técnicas para a Gestão da Cadeia de Suprimento.

No caso da Previsão de Demanda, os resultados mostraram que nem sempre o melhor modelo resulta em uma previsão correta, visto que eventos atípicos alteraram o comportamento das séries temporais. Esse fato ressaltou a importância da integração da área com os especialistas, já que a posse das informações no tempo real permite que possíveis ajustes sejam feitos de modo a obter maior precisão na previsão. Segundo o critério adotado nesse trabalho, os modelos que produziram os menores erros para as previsões dos mercados estudados foram ARIMA e Suavização Exponencial Simples. De posse dos dados das previsões de demanda, é possível gerenciar de modo mais eficiente os estoques de produto acabado e de matéria-prima. Outro

ponto importante a ser destacado é a possibilidade de utilizar essa informação como dado de entrada para a etapa de simulação computacional.

Com o uso da Simulação Computacional, foi feita a modelagem da unidade fabril do presente estudo de caso. Essa modelagem permitiu propor diversos cenários, cujos resultados foram analisados de forma a garantir a melhor alocação dos recursos para atender a demanda prevista. As análises possibilitaram visualizar as respectivas limitações, ociosidades e capacidades de cada processo, identificando gargalos e desbalanceamentos da linha. A partir dessas informações foi possível propor soluções que aperfeiçoam os recursos, tornando a empresa mais enxuta e eficiente, para atender às variações das demandas previstas. Outro beneficio observado foi à possibilidade de ter uma visão sistêmica dos efeitos que alterações nos processos terão sobre o desempenho global dos fluxos de produção, possibilitando a criação de cenários futuros sem a necessidade de investimentos reais.

Com base nos resultados obtidos pode-se sugerir que novos critérios para tratamento dos dados da Série Temporal sejam avaliados de modo a melhorar a precisão das demandas previstas, podendo utilizar também os Modelos *Bayesianos*. Outra sugestão é que sejam estudadas outras técnicas que possibilitem melhorar a integração entre as cadeias da empresa. Além disso, recomenda-se o estudo do gerenciamento dos estoques e do seqüenciamento da produção.

Referências Bibliográficas

Bowersox, D.; Closs, D. J. Logística Empresarial: O Processo de Integração da Cadeia de Suprimento, 1ª edição, Atlas, 2007.

Chopra, S.; Meindl, P. Gerenciamento da Cadeia de Suprimentos: Estratégia, Planejamento e Operação, 1ª edição, Pearson Prentice Hall, 2003.

Dagnoni, M. R. F.; Krauss, V. A. Empresas Familiares: Desafios e oportunidades na gestão e sucessão. *Revista de Divulgação Técnico-Científica do ICPG*, 3, 49 – 53, 2007.

Greasley, A. Using simulation for facility design: A case study**.** *Simulation Modelling Practice and Theory* 16, 670–677, 2008.

Grzybovski, D.; Tedesco, J. C. Empresa Familiar x Competitividade: Tendências e Racionalidades em Conflito. *Teoria e Evidência Econômica*, 6,37-68, 1998.

Harrell, C.R.; Ghosh, B.K. e Bowden, R. Simulation Using ProModel, 2ª edição, McGraw-Hill Professional, 2004.

Harrel, C. R.; Bateman, R. E.; Gogg, T. J. e Mott, J. R. A. System Improvement Using Simulation, 1º edição, McGraw-Hill, 2000.

Law, A. M.; Kelton, W. D. Simulation Modeling and Analysis. 3ª edition. McGraw-Hill, 2000.

McClellan, J.J. The benefit of using simulation to improve the implementation of lean manufacturing case study: quick changeovers to allow level loading of the assembly line. Dissertação de mestrado, Brigham Young University, 2004.

McLean, C.; Leong, S. The Role of Simulation in Strategic Manufacturing. Proceedings of the 33nd Conference on Winter Simulation, 1478-1486, 2001.

Sandanayake, Y.G.; C. F. Oduoza; D. G. Proverbs. A systematic modelling and simulation approach for JIT performance optimization. *Robotics and Computer-Integrated Manufacturing* 24, 735– 743, 2008.

Sanders, N. R.; Manrodt, K. B. The efficacy of using judgmental versus quantitative forecasting methods in practice. *Omega*, 31**,** 511 – 522, 2003.

Wanke et al. Previsão de vendas: processos organizacionais & métodos quantitativos e qualitativos, 1ª edição, Atlas, 2006.

Werner, L.; Ribeiro, J.L.D. Modelo composto para prever demanda através da integração de previsões, Produção, v. 16, n. 3, páginas 493-509, 2006.