

**UNIVERSIDADE FEDERAL DO RIO GRANDE DO SUL
ESCOLA DE ENGENHARIA
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA DE PRODUÇÃO**

**CURVAS DE APRENDIZADO COMO BALIZADORAS
DA ALOCAÇÃO DE MODELOS DE PRODUTOS A
EQUIPES DE TRABALHADORES**

Michel José Anzanello

Porto Alegre, 2004

**UNIVERSIDADE FEDERAL DO RIO GRANDE DO SUL
ESCOLA DE ENGENHARIA
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA DE PRODUÇÃO**

**CURVAS DE APRENDIZADO COMO BALIZADORAS DA ALOCAÇÃO DE
MODELOS DE PRODUTOS A EQUIPES DE TRABALHADORES**

Michel José Anzanello

Orientador: Flávio Sanson Fogliatto, *Ph.D.*

Banca Examinadora:

**Eugenio Kahn Epprecht, Dr.
Prof. Depto. Engenharia Industrial / PUC-RJ**

**José Luís Duarte Ribeiro, Dr.
Prof. Depto. Engenharia da Produção / UFRGS**

**Fernando Gonçalves Amaral, Dr.
Prof. PPGEP / UFRGS**

**Dissertação submetida ao Programa de Pós-Graduação em Engenharia de
Produção como requisito parcial à obtenção do título de
MESTRE EM ENGENHARIA DE PRODUÇÃO**

Área de concentração: Qualidade e Gerência de Serviços

Porto Alegre, abril de 2004.

Esta dissertação foi julgada adequada para a obtenção do título de Mestre em Engenharia de Produção e aprovada em sua forma final pelo Orientador e pela Banca Examinadora designada pelo Programa de Pós-Graduação em Engenharia de Produção.

Prof. Flávio Sanson Fogliatto, *Ph.D.*
Universidade Federal do Rio Grande do Sul
Orientador

Prof. José Luis Duarte Ribeiro, Dr.
Coordenador PPGE/UFGRS

Banca Examinadora:

Eugenio Kahn Epprecht, Dr.
Prof. Depto. Engenharia Industrial / PUC - RJ

José Luís Duarte Ribeiro, Dr.
Prof. Depto. Engenharia da Produção / UFRGS

Fernando Gonçalves Amaral, Dr.
Prof. PPGE / UFRGS

*A minha família, em especial
à vó Olímpia e à Dinda, pelas
inestimáveis contribuições à
formação do meu caráter.*

AGRADECIMENTOS

Ao findar deste trabalho, gostaria de expressar meus sinceros agradecimentos a todos aqueles que, de uma forma ou de outra, contribuíram para a realização desta dissertação.

Em especial, agradeço ao professor Flávio Sanson Fogliatto, exemplo de profissional centrado e dotado de senso crítico. Obrigado pelos conselhos, considerações e incentivos, os quais foram de fundamental importância para a elaboração do estudo.

Ao professor José Luís Duarte Ribeiro, pelas dicas e sugestões que muito auxiliaram no desenvolvimento do trabalho.

Aos companheiros de mestrado e, mais do que tudo, amigos: Antônio Sérgio Galindo Falcão, Fernando de Oliveira Lemos, Paulo Ricardo Santos da Silva e Tiago Pascoal Filomena. De fato, as discussões valeram.

A minha família, pelo apoio e incentivo prestados não somente durante a minha carreira acadêmica, mas durante toda a minha vida. E a Adriana, pelo carinho, compreensão e companheirismo nos mais diversos momentos de elaboração desta dissertação.

À empresa calçadista Reifer, em especial ao Hélio Diedrich e ao Paulo Eidelwein, por propiciarem um ambiente adequado à realização do estudo de caso, através do fornecimento de informações e considerações sobre um setor desconhecido até então.

E a Deus, por tudo.

“Nada verdadeiramente valioso advém da ambição ou do mero senso do dever; é melhor que venha do amor e da devoção à humanidade e às coisas objetivas.”

Albert Einstein

RESUMO

Em cenários de produção baseados na flexibilidade de catálogo, uma grande variedade de modelos de produtos é demandada pelos consumidores. Essa condição exige uma rápida adequação dos meios produtivos às especificações do próximo modelo a ser produzido. Tal situação, contudo, pode acarretar perdas consideráveis em relação aos níveis de produção e qualidade, em decorrência da pouca habilidade dos trabalhadores nos ciclos iniciais de produção de um novo modelo. Assim, a modelagem do processo de aprendizado de trabalhadores atuando sobre cada modelo de produto pode auxiliar a gerência na alocação de modelos de produtos a equipes de trabalhadores, minimizando as perdas verificadas nos primeiros ciclos de produção. Esta dissertação propõe uma metodologia baseada na utilização de curvas de aprendizado como balizadoras da alocação de modelos de produtos a equipes de trabalhadores. Os diversos modelos de produtos são agrupados em famílias de acordo com suas características similares, permitindo uma redução na coleta de dados. A alocação das famílias às equipes é realizada através da análise das curvas de aprendizado. Duas formas de alocação são apresentadas, de acordo com a duração da corrida de produção. A metodologia proposta é ilustrada através de um estudo de caso em uma indústria do setor calçadista.

ABSTRACT

In a catalogue flexibility production scenario a great variety of models is typically demanded by consumers. That requires fast setup of production resources to comply with the production specifications of the next model to be produced. Such compliance, however, may induce considerable production and quality losses due to workers' poor performance during the initial production runs of a new model. Therefore, modeling workers' learning upon exposure to each product model may help production managers to define the best allocation scheme for models and workers, such that losses in the initial stages of production are minimized. This thesis presents a methodology that uses workers' learning curves to guide the best allocation of product models to teams of workers. Different product models are first grouped in families based on their similarities, leading to a smaller data collection. Then allocation of product families to teams is conducted based on the analysis of their respective learning curves. Two courses of action are proposed for that matter, depending on whether the production batch will lead to longer or shorter production runs. The proposed methodology is illustrated in a case study from the shoe manufacturing industry.

SUMÁRIO

1	INTRODUÇÃO	16
1.1	Considerações Iniciais.....	16
1.2	Justificativa do Tema	17
1.3	Objetivos	19
1.3.1	Objetivo Principal	19
1.3.2	Objetivos Específicos	19
1.4	Metodologia	20
1.4.1	Método de Pesquisa	20
1.4.2	Método de Trabalho.....	20
1.5	Estrutura da Dissertação.....	21
1.6	Delimitações.....	21
2	REVISÃO BIBLIOGRÁFICA	23
2.1	Introdução.....	23
2.2	Processo de Aprendizado	24
2.3	Curvas de Aprendizado	31
2.3.1	Modelo Potencial (Modelo de Wright).....	31
2.3.2	Demais Modelos de Curvas de Aprendizado de Natureza Potencial.....	44
2.3.3	Modelos Exponenciais	48
2.3.4	Modelos Hiperbólicos.....	51
2.3.5	Modelos de Esquecimento	61
2.3.6	Modelos Multivariados	65

2.4	Análise de Clusters.....	67
2.4.1	Variáveis de Clusterização.....	67
2.4.2	Medições de Similaridade.....	68
2.4.3	Formação de <i>Clusters</i>	69
2.4.4	Escolha do Método de Clusterização.....	70
2.4.5	Interpretação e Avaliação dos Resultados	71
2.5	Regressão Linear Múltipla	72
2.5.1	Determinação dos Coeficientes de Regressão	73
2.5.2	Adequação do Modelo de Regressão.....	75
3	MÉTODO PROPOSTO.....	78
3.1	Identificação e Agrupamento dos Produtos com Características Similares.....	81
3.2	Identificação da Amostra de Trabalhadores a ser usada na Coleta de Dados	83
3.3	Cruzamento entre as Equipes de Trabalhadores e as Famílias de Produtos.....	84
3.4	Modelagem dos Dados de Desempenho obtidos nos Cruzamentos através de Modelos de Curvas de Aprendizado apresentados Na literatura.....	87
3.5	Análise dos Parâmetros gerados pela Curva de Aprendizado Seleccionada.....	89
3.5.1	Análise de Regressão sobre o Parâmetro de Taxa de Aprendizado (r) resultante da modelagem	90
3.5.2	Análise das Curvas de Aprendizado construídas a partir dos Parâmetros gerados pela Modelagem.....	92
3.6	Alocação das Famílias de Produtos às Equipes de Trabalhadores.....	96
4	ESTUDO DE CASO.....	97
4.1	Identificação e Agrupamento dos Produtos com Características Similares.....	98
4.2	Identificação da Amostra de Trabalhadores a ser usada na Coleta de Dados	100
4.3	Cruzamento entre as Equipes de Trabalhadores e as Famílias de Produtos.....	101
4.4	Modelagem dos Dados de Desempenho obtidos nos Cruzamentos através de Modelos de Curvas de Aprendizado apresentados Na literatura.....	106
4.5	Análise dos Parâmetros gerados pela Curva de Aprendizado Seleccionada.....	110
4.5.1	Análise de Regressão sobre o Parâmetro de Taxa de Aprendizado (r) resultante da modelagem	110
4.5.2	Análise das Curvas de Aprendizado construídas a partir dos Parâmetros gerados pela Modelagem.....	114

4.6	Alocação das Famílias de Produtos às Equipes de Trabalhadores.....	119
5	CONCLUSÃO.....	122
	REFERÊNCIAS.....	125
	APÊNDICES.....	133

LISTA DE FIGURAS

Figura 1: Esquema da aquisição de conhecimento (Adaptado de VITS; GELDERS, 2002)..	28
Figura 2: Gráfico da curva de aprendizado segundo o modelo de Wright (Adaptado de JABER; BONNEY, 2001).....	32
Figura 3: Etapas do aprendizado, segundo Jaber e Bonney (1999) <i>apud</i> Blancett (2002).....	36
Figura 4 : Comparação dos modelos de curva de aprendizado de natureza potencial em escala logarítmica (Adaptado de BADIRU, 1992).....	48
Figura 5: Representação gráfica das equações hiperbólicas (15) e (16) (Adaptado de UZUMERI; NEMBHARD, 1998).....	52
Figura 6: Gráfico tridimensional do aprendizado organizacional (adaptado de UZUMERI; NEMBHARD, 1998).....	56
Figura 7: Correlações dos parâmetros k , p e r (Adaptado de UZUMERI; NEMBHARD, 1998)	57
Figura 8: Efeito do esquecimento no desempenho (Adaptado de GLOBERSON <i>et al.</i> (1989))	62
Figura 9: Gráfico genérico de uma curva de aprendizado bivariada (Adaptado de BADIRU, 1992).....	66
Figura 10: Gráfico de probabilidade normal dos resíduos (Adaptado de MONTGOMERY; PECK, 1992).....	75
Figura 11: Distribuição aleatória do resíduo (Adaptado de MONTGOMERY; RUNGER, 1994).....	76
Figura 12: Fluxograma do método proposto	81
Figura 13: Arranjo das características dos produtos.....	82

Figura 14: Arranjo dos dados de desempenho coletados para cada produto.....	85
Figura 15: Análise das áreas geradas pelas curvas para uma família de produtos <i>X</i>	94
Figura 16: Perfis de aprendizado descritos pelos três modelos de curvas na produção do <i>Calçado 24</i>	107
Figura 17: Perfis gerados na execução de calçados pertencentes à Família <i>Fácil</i>	115
Figura 18: Perfis gerados na execução de calçados pertencentes à Família <i>Média</i>	116
Figura 19: Perfis gerados na execução de calçados pertencentes à Família <i>Difícil</i>	116

LISTA DE QUADROS

Quadro 1: Características e perfis das curvas em função do parâmetro r	53
Quadro 2: Resumo das principais características dos modelos de curvas de aprendizado univariados	60
Quadro 3: Significado dos parâmetros dos modelos de curvas de aprendizado avaliados.....	87
Quadro 4: Escala codificada para equipes de trabalhadores (X_1) e famílias de produtos (X_2)	91
Quadro 5: Operação de costura monitorada para cada calçado.....	102
Quadro 6: Resumo das alocações sugeridas pelos métodos	121

LISTA DE TABELAS

Tabela 1: Desempenho dos modelos de curvas de aprendizado (Adaptado de NEMBHARD; UZUMERI, 2000a).....	59
Tabela 2: Áreas geradas pela integral da curva de aprendizado para duas equipes	94
Tabela 3: Matriz dos atributos dos calçados analisados e família a que cada modelo foi alocado.....	100
Tabela 4: Dados de desempenho coletados e convertidos para o modelo <i>Calçado 24</i>	104
Tabela 5: Parâmetros gerados pelas curvas de aprendizado avaliadas.....	106
Tabela 6: Desvios das estimativas geradas pelos 3 modelos de curvas para o <i>Calçado 24</i> ..	108
Tabela 7: Resumo dos erros (SQE), coeficientes de determinação (R^2) e desvios resultantes das modelagens.....	109
Tabela 8: Valores de escala atribuídos às equipes monitoradas.....	110
Tabela 9: Escalas codificadas e parâmetros r_{ij} obtidos através das modelagens por curvas de aprendizado.....	111
Tabela 10: Significâncias das variáveis independentes do modelo de regressão obtido.....	112
Tabela 11: Comparação entre os valores de r_{ij} modelados pela curva de aprendizado e os estimados pelo modelo de regressão	113
Tabela 12: Procedimento de obtenção dos parâmetros médios para 3 modelos de calçados	115
Tabela 13: Áreas geradas pelas 3 equipes na execução das operações relativas à Família <i>Difícil</i>	118

CAPÍTULO 1

1 INTRODUÇÃO

1.1 CONSIDERAÇÕES INICIAIS

O mercado tem imposto severas condições para a sobrevivência das empresas em um cenário altamente competitivo. As mudanças sociais, políticas e econômicas, bem como os avanços da ciência, promoveram acentuadas modificações nos meios produtivos. Esse processo estendeu-se ao consumidor, o qual passou a ser mais exigente quanto aos seus direitos. A qualidade intrínseca dos produtos, outrora um diferencial competitivo, passou a ser quesito indispensável para a permanência de uma empresa no seu ramo de atuação (DE RON, 1998).

A fim de buscar novas estratégias capazes de diferenciar seus produtos, as empresas passaram a investir em uma maior variedade de catálogo. A oferta de uma maior gama de opções de produto passou a ser encarada como uma característica desejada pelos clientes, que em muitos casos estão dispostos a pagar preços mais elevados por itens diferenciados (SILVEIRA *et al.*, 2001). As empresas passaram a vislumbrar um mercado bastante próspero na fabricação de produtos diferenciados, sendo exemplos desta realidade setores de montagem em geral e indústrias do ramo calçadista.

Empresas que optaram pela produção baseada na flexibilidade de catálogo passaram a operar com lotes de tamanho reduzido em seus processos produtivos. Tais lotes passaram a sofrer modificações freqüentes nas características dos produtos ou parâmetros de processo,

exigindo adaptações do meio produtivo em relação ao maquinário e à mão-de-obra envolvidos.

A alteração constante nos modelos dos produtos submete o trabalhador a novas tecnologias e habilidades, desencadeando um processo de aprendizado a cada nova tarefa que lhe é imposta. À medida que repetições da nova tarefa são executadas, o desempenho do trabalhador atinge melhores níveis de produtividade (TOWILL, 1990).

A adaptação do trabalhador a um novo produto ou serviço, contudo, pode impor consideráveis perdas ao sistema produtivo, tornando útil a avaliação do processo de aprendizado. Dentro deste contexto, a curva de aprendizado tem se mostrado uma ferramenta útil no monitoramento do desempenho do trabalhador submetido a uma nova tarefa, avaliando seu progresso à medida que repetições são efetuadas. Essas curvas foram introduzidas por Wright em 1936, através da verificação da redução do tempo e custo necessários para a montagem de aviões durante a Primeira Guerra Mundial. Desde então, as curvas de aprendizado têm sido utilizadas para avaliação do tempo demandado para conclusão de corridas de produção, estimação da redução de custos de produção e previsão de desempenho dos trabalhadores quando submetidos a uma nova tarefa (TEPLITZ, 1991).

Este trabalho propõe uma sistemática de utilização das curvas de aprendizado para balizar a alocação de produtos a equipes de trabalhadores. A sistemática sugerida é ilustrada em uma aplicação no setor de costura de uma indústria calçadista, com o propósito de mensurar e avaliar o desempenho dos trabalhadores na fabricação de determinados modelos de calçados. As curvas serão usadas para designar trabalhadores - ou equipes de trabalhadores - aptos a atuarem em determinados modelos de calçados, de maneira a reduzir as perdas decorrentes das trocas de modelo de produto.

1.2 JUSTIFICATIVA DO TEMA

A flexibilidade de catálogo pressupõe produção de grande variedade de itens e alteração constante no tamanho dos lotes de produtos demandados, exigindo flexibilidade dos recursos e interação dos meios produtivos (maquinário e mão-de-obra) para se adaptarem de maneira rápida e precisa às modificações impostas (SILVEIRA *et al.*, 2001). O processo de adaptação dos meios de produção ao novo procedimento ou produto geralmente traz consigo perdas pronunciadas (baixos índices de produção e de qualidade nas primeiras unidades

produzidas, entre outras), decorrentes principalmente da pouca habilidade dos trabalhadores em executar uma tarefa desconhecida (UZUMERI; NEMBHARD, 1998).

Indústrias do setor de montagem, como a automobilística e a calçadista, são exemplos de áreas onde se verificam perdas pela introdução de um novo procedimento ou modelo de produto. A indústria de calçados tem seu processo baseado em atividades manuais, as quais se modificam quando da alteração do modelo em fabricação. Segundo Jacinto (2001), as perdas decorrentes das trocas de modelos na indústria calçadista correspondem a 32% da produção total dos 3 primeiros dias, sendo causadas pela pouca habilidade do trabalhador nos primeiros ciclos de produção dos novos modelos. A troca freqüente de modelos de calçados nas linhas exige ajuste de máquinas e, principalmente, readaptação de trabalhadores à nova tarefa, o que acarreta diminuição de desempenho nos ciclos iniciais de produção. Além dessa redução, a qualidade dos produtos fabricados nos primeiros ciclos também diminui em relação àquela obtida quando o trabalhador está familiarizado com a tarefa (TEPLITZ, 1991). Ou seja, existe uma variabilidade inerente à introdução de novos produtos em uma linha de produção para esse tipo de indústria, decorrente principalmente da participação humana no processo.

Entretanto, apesar do conhecimento consolidado a respeito da variabilidade humana na realização de tarefas manuais, há uma carência de métodos na literatura que permitam avaliar a adaptação dos trabalhadores às operações e possibilitem a alocação dos mesmos a produtos cujas corridas de produção apresentam durações distintas.

Esta dissertação busca suprir tal lacuna, propondo a utilização de curvas de aprendizado para minimizar a variabilidade humana na realização de operações relativas a novos produtos. As curvas de aprendizado são utilizadas como balizadoras da alocação de produtos a equipes de trabalhadores, permitindo o direcionamento dos diversos modelos de produtos às equipes mais aptas à realização de suas operações. Os parâmetros da curva de aprendizado permitem analisar quantitativamente a adaptação dos trabalhadores às operações avaliadas, possibilitando a identificação de perfis distintos de aprendizado que poderão ser administrados de acordo com os modelos de produtos demandados.

Desta forma, justifica-se a modelagem do desempenho de equipes de trabalhadores submetidas a uma nova tarefa por meio de curvas de aprendizado, objetivo desta dissertação. Tomando como exemplo o estudo de caso aqui apresentado, diversos modelos de calçados serão agrupados segundo suas características similares através de técnicas de clusterização, de maneira a reduzir a quantidade de dados a serem coletados e analisados. As famílias de calçados geradas passarão a ser direcionadas para as equipes com formação definida. O

desempenho de cada equipe na execução das operações será avaliado através de curvas de aprendizado, permitindo o direcionamento preciso dos produtos às equipes mais aptas à realização das operações. Busca-se a redução dos efeitos decorrentes da pouca habilidade dos trabalhadores nos primeiros ciclos de trabalho (exemplificados pelos baixos níveis de produção e qualidade dos produtos) e uma melhor resposta de adequação dos meios produtivos frente às freqüentes modificações de modelos de produtos.

1.3 OBJETIVOS

1.3.1 Objetivo Principal

O principal objetivo desta dissertação é a proposição de uma metodologia de utilização das curvas de aprendizado como balizadoras da alocação de produtos (trabalhos) a equipes de trabalhadores.

1.3.2 Objetivos Específicos

Constituem os objetivos específicos deste trabalho:

- Levantar o estado da arte sobre modelos de curvas de aprendizado e suas aplicações na literatura especializada.
- Mensurar e analisar o potencial de aprendizado de equipes de trabalhadores segundo a teoria de curvas de aprendizado.
- Avaliar a aderência e capacidade preditiva de três modelos de curvas de aprendizado distintos.
- Propor e validar empiricamente um modelo de regressão associando parâmetros de curvas de aprendizado com características de equipes de trabalhadores e produtos.
- Comparar duas formas distintas de análise dos parâmetros gerados pelas modelagens através de curvas de aprendizado, de acordo com a duração da corrida de produção.
- Apresentar uma aplicação prática do procedimento proposto na indústria calçadista.

1.4 METODOLOGIA

1.4.1 Método de Pesquisa

Segundo a natureza, este trabalho é classificado como pesquisa aplicada, tendo em vista que seu conteúdo teórico é explorado e direcionado à solução de problemas genéricos (GIL, 1991). Considerando-se a abordagem, esta dissertação é enquadrada como pesquisa quantitativa, pois faz uso de análises numéricas.

Do ponto de vista de seus objetivos, este trabalho enquadra-se na classe de pesquisa exploratória, visto que permite entrar em contato com o problema e possibilita construir hipóteses para solucioná-lo.

Os procedimentos utilizados para execução deste trabalho são pesquisa bibliográfica e estudo de caso. A estruturação teórica do trabalho provém de material já publicado, constituindo a pesquisa bibliográfica. O estudo de caso é uma metodologia aplicável quando surgem questionamentos do tipo “como” e “por que”, quando o evento estudado não permite um controle por parte dos pesquisadores e quando o objetivo está baseado em fenômenos contemporâneos inseridos em uma aplicação atual (YIN, 2001). Segundo Gil (1991), o estudo de caso é focado na investigação de um ou mais objetos, gerando-se condições para o entendimento profundo do objeto e desenvolvendo-se fundamentos para a construção de conclusões a respeito do mesmo.

1.4.2 Método de Trabalho

O desenvolvimento deste trabalho será feito em quatro etapas. A primeira etapa está baseada no levantamento bibliográfico em torno das curvas de aprendizado.

O conhecimento dos vários modelos de calçados produzidos pela empresa e o agrupamento dos mesmos, de acordo com suas similaridades, é efetuado na segunda etapa.

A terceira etapa compreende o levantamento de dados de desempenho e a modelagem dos mesmos através de curvas de aprendizado, buscando avaliar o aprimoramento de cada equipe de trabalhadores na fabricação das famílias de modelos de produtos.

Na última etapa, os parâmetros gerados pela modelagem são analisados através de dois métodos distintos, segundo a duração estimada da corrida de produção analisada. Os métodos

de regressão dos parâmetros e de integração das curvas permitem identificar a equipe que apresentou a melhor adaptação aos preceitos de execução de cada produto analisado. De tal forma, é possível direcionar tal produto à equipe mais habilitada, minimizando os efeitos de troca de modelo de produto.

1.5 ESTRUTURA DA DISSERTAÇÃO

O trabalho está estruturado em cinco capítulos, com conteúdos delineados na seqüência.

O Capítulo 1 apresenta uma breve introdução, seguida do tema escolhido e sua justificativa, bem como os objetivos do trabalho e o método escolhido para atingi-los. No final, apresentam-se as limitações do trabalho.

No Capítulo 2 faz-se uma revisão bibliográfica do tema escolhido, buscando apresentar de forma clara e objetiva os fundamentos teóricos dos modelos de curvas de aprendizado. São levantadas as aplicações desta ferramenta em vários setores, bem como as principais conclusões e restrições em torno dessas aplicações.

A apresentação da metodologia para alocação de produtos a equipes com base na utilização de curvas de aprendizado é feita no Capítulo 3.

No Capítulo 4 aplica-se a modelagem desenvolvida em uma empresa do setor calçadista e apresentam-se os resultados obtidos.

As conclusões decorrentes do estudo de caso, bem como sugeridas extensões para este trabalho, são apresentadas no Capítulo 5.

1.6 DELIMITAÇÕES

As curvas de aprendizado podem ser utilizadas em diversos setores de produção e serviços, desde que sua aplicação esteja condicionada a características específicas de cada caso. Por isso, existem limitações inerentes à aplicação das curvas de aprendizado.

Uma limitação geral para a utilização de curvas de aprendizado refere-se ao conceito de “aprendizado”, entendido como a adequação em termos de destreza do trabalhador aos preceitos de execução de uma tarefa manual, demandando menor tempo para realização da

mesma à medida que repetições são efetuadas (TEPLITZ, 1991). Outras formas de aprendizado que não envolvam a execução de movimentos repetitivos demandam outras formas de análise ou adaptações dos modelos de curvas de aprendizado existentes.

O método proposto se limita a monitorar os períodos de aprendizado e de estabilização do desempenho dos trabalhadores na tarefa, não abordando etapas posteriores em que se verifica queda de rendimento decorrente de fadiga.

Os modelos de curvas de aprendizado avaliados na metodologia proposta não apresentam parâmetros específicos para o controle da qualidade dos itens produzidos durante o processo de adaptação dos trabalhadores, avaliando somente os níveis de produtividade.

A metodologia proposta não leva em consideração a influência do modelo de produto que acaba de ser produzido sobre a adaptação do trabalhador ao novo produto que entrará em produção.

O método sugerido não avalia a influência do dia da semana e nem da hora do dia em que começa a execução do novo modelo de produto, o que pode afetar o desempenho do trabalhador devido ao cansaço acumulado durante a jornada. Também não são avaliadas variáveis como temperatura no ambiente de trabalho, a qual varia consideravelmente durante o período de trabalho.

CAPÍTULO 2

2 REVISÃO BIBLIOGRÁFICA

2.1 INTRODUÇÃO

A customização da produção tem se tornado uma estratégia competitiva importante na indústria, visto que produtos diferenciados apresentam melhor potencial de aceitação pelo mercado consumidor. Essa estratégia de produção está fundamentada em processos altamente integrados e dotados de grande flexibilidade, características que permitem alterações freqüentes no processo de produção (SILVEIRA *et al.*, 2001).

A produção baseada em pequenos lotes de produtos se configura como uma característica da flexibilidade de catálogo. Essa política de produção, contudo, acarreta modificações no padrão de trabalho a cada troca de produto, levando os meios produtivos a um processo freqüente de adaptação. Os trabalhadores são submetidos a alterações na forma de realização da tarefa, sendo conduzidos a um processo de aprendizado e aprimoramento de destreza a cada nova modalidade de tarefa (UZUMERI; NEMBHARD, 1998).

Tal aprendizado assume grande importância no desempenho dos trabalhadores, principalmente quando esses executam um número significativo de tarefas no processo produtivo. As atividades manuais são fontes de perdas consideráveis quando executadas por trabalhadores com conhecimento reduzido da tarefa. A ineficiência do trabalhador na execução de uma tarefa pode ser decorrente de um processo de treinamento insuficiente,

condições inadequadas de trabalho ou inaptidão para realização da tarefa, revelando uma alocação equivocada por parte da gerência (UZUMERI; NEMBHARD, 1998).

Dentro desse contexto, a curva de aprendizado, proposta inicialmente por Wright em 1922, se apresenta como uma ferramenta capaz de monitorar o desempenho de trabalhadores submetidos a tarefas cuja forma de realização modifica-se frequentemente. Através das curvas é possível analisar e programar tarefas produtivas, reduzindo perdas decorrentes da inabilidade do trabalhador, as quais são verificadas principalmente nos primeiros ciclos de produção. A ferramenta também permite a alocação adequada de membros de uma população de trabalhadores a determinadas tarefas, obedecendo as suas características de atuação (TEPLITZ, 1991).

A seção seguinte apresenta uma abordagem superficial do processo de aprendizado focado na assimilação de procedimentos manuais (aquisição de destreza), bem como os fatores que influenciam esse processo. Na seqüência, é avaliado o estado da arte das curvas de aprendizado, abordando-se os fundamentos matemáticos, aplicações e limitações dos modelos mais difundidos na literatura. Fundamentos de clusterização são citados por se constituírem em importante subsídio para a organização dos produtos a serem analisados. Uma breve análise dos preceitos de regressão linear múltipla propicia condições para análises complementares dos resultados obtidos pela modelagem através de curvas de aprendizado.

2.2 PROCESSO DE APRENDIZADO

As profundas modificações do mercado, principalmente no que diz respeito à demanda por produtos diferenciados, faz com que as empresas se preocupem em responder de maneira rápida e qualificada às exigências do consumidor, sob pena de perderem competitividade. Linhas de montagem que costumavam trabalhar inalteradas por longos períodos passaram a ser frequentemente reconfiguradas, principalmente em processos de alta tecnologia. As inovações de procedimento e alterações nas características dos produtos promovem um ambiente onde os trabalhadores passam grande parte do seu expediente em processo de aprendizado e adaptação a novas tarefas (UZUMERI; NEMBHARD, 1998).

Frente a esta realidade, empresários e administradores têm atentado para a necessidade de uma rápida e eficiente aquisição de conhecimento pelos diversos níveis da organização. O conhecimento das etapas do processo, outrora focado em trabalhadores específicos, passou a

ser direcionado para toda a força de trabalho, dando origem ao conceito de aprendizado organizacional. Para Kilbridge (1962), o aprendizado organizacional tem importância fundamental em um grande número de processos que operam em linha, visto que todos os trabalhadores têm que atuar com um ritmo semelhante, o que demanda níveis homogêneos de conhecimento e destreza na tarefa. Uzumeri e Nembhard (1998) entendem que essa nova abordagem de aprendizado permite à gerência o conhecimento mais amplo do seu potencial de mão-de-obra, possibilitando maior clareza quanto aos investimentos em treinamento e alocação de trabalhadores.

O aprendizado organizacional pode ser encarado como meio para a conquista de competências específicas no mercado. Cada trabalhador é visto como uma unidade básica do mecanismo de aprendizado dentro da organização, sendo a transferência do conhecimento para o restante do grupo responsabilidade do trabalhador e da empresa em que ele está inserido. Mehra e Dhawan (2003) realizaram estudos em empresas indianas voltadas para o desenvolvimento de *softwares*, buscando analisar fatores que influenciavam o ambiente de aprendizado de membros de uma equipe de trabalhadores. Dentre vários fatores identificados, destacaram-se a flexibilidade dos meios de treinamento, saúde organizacional, interação entre trabalhadores e oportunidades para aprendizado. Segundo os autores, o conceito de *empowerment* também passou a ser expressivo no contexto de aprendizado organizacional.

Agrell, Bagetoft e Tind (2002) apontam a dificuldade enfrentada pela gerência para difundir preceitos de melhorias e conhecimento de maneira eficiente através da organização, principalmente em setores onde o processo depende da participação de vários trabalhadores. Para tanto, propuseram uma estrutura capaz de incentivar a transferência de conhecimento através dos vários níveis da força de trabalho. Tal estrutura está baseada em três premissas: aprender, ensinar e inovar. A estrutura complementa-se com a inclusão de programas de treinamento e divisão de lucros da empresa entre os trabalhadores. Nembhard e Uzumeri (2000a) alertam para a necessidade de escolha adequada de um método para avaliação do aprendizado organizacional. Os métodos tradicionalmente utilizados agregam os trabalhadores sem levar em conta características particulares de cada membro, as quais possibilitariam descrições mais precisas do desempenho de cada trabalhador.

Para Nembhard e Uzumeri (2000b), o entendimento do processo de aprendizado pela gerência e trabalhadores é fundamental para o sucesso em várias etapas do processo de produção. Tal entendimento fornece subsídios para uma eficiente programação de produção, bem como para otimização de tempos de treinamento dos trabalhadores. As tarefas a serem

assimiladas podem ser divididas em dois grupos principais. O primeiro grupo é constituído das tarefas cognitivas, onde é exigido grande raciocínio durante a execução das tarefas, mas a assimilação do procedimento se dá de forma rápida. Tarefas cognitivas no meio industrial podem ser exemplificadas pela operação de maquinários e equipamentos em operações onde não se verificam procedimentos repetitivos com grande frequência. O segundo grupo é constituído das tarefas manuais, as quais exigem uma série de movimentos seqüenciais e repetitivos, demandando destreza por parte do trabalhador. As tarefas manuais são de assimilação mais lenta, porém os procedimentos são retidos por maiores períodos (WICKENS; GORDON; LIU, 1998).

O processo de aquisição de conhecimento tem sido estudado em várias perspectivas e com diferentes objetivos. Áreas relacionadas à Engenharia têm se focado na modelagem desses processos com o intuito de monitorar custos e horas de trabalho necessárias para execução de corridas de produção (DAR-EL; RUBINOVITZ, 1991).

Ciências relacionadas à psicologia e ergonomia também têm estudado o processo de aprendizado, propondo modelos para explicação do mecanismo de aquisição e retenção de conhecimento, e identificando fatores que influenciam no processo (ANDERSON, 1982). Eyring Johnson e Francis (1993) realizaram estudos que apontaram fatores responsáveis pelos diferentes níveis de aquisição de conhecimento e habilidade por parte do trabalhador frente a uma tarefa, sendo a familiaridade com a tarefa e a motivação do trabalhador em executá-la os fatores mais pronunciados. Também para Kanfer (1990), a motivação é um fator determinante na aquisição de habilidades em atividades de mais alta complexidade.

A experiência anterior na tarefa em questão, ou familiaridade, constitui um fator significativo no processo de aprendizado. Para Nembhard e Osothsilp (2002), o fato de o trabalhador ter desempenhado a operação em algum momento de sua vida lhe possibilita um desempenho diferenciado, principalmente nos primeiros ciclos de produção. Nembhard e Uzumeri (2000a) afirmam que trabalhadores que já contam com experiência prévia na execução da tarefa tendem a atingir patamares mais elevados de desempenho final. Entretanto, Nembhard e Uzumeri (2000b) mostram que, em algumas tarefas, trabalhadores com experiência assimilam procedimentos de maneira mais lenta, visto que há menos o que aprender neste caso.

Pananiswaml e Bishop (1991) desenvolveram pesquisas na busca de características da tarefa capazes de influenciar o processo de aprendizado. Dentre essas, a complexidade do produto ou do processo mostrou-se a maior responsável pela diferença no desempenho de

trabalhadores submetidos a tarefas desconhecidas. Nembhard e Osothsilp (2002) estudaram o efeito da complexidade da tarefa sobre os parâmetros do modelo de aprendizado proposto por Uzumeri e Nembhard (1998) para descrição do processo de aprendizado. Concluíram que um aumento da complexidade da tarefa resulta em uma maior variabilidade dos parâmetros do modelo, o que pode ser traduzido como maiores disparidades no desempenho dos trabalhadores ao executarem tarefas complexas.

A variabilidade de desempenho dos trabalhadores em uma tarefa também pode ser causada pelo modo operatório, ou seja, o estilo com que cada trabalhador executa determinada tarefa (*workstyle*). Esse fator pode ser definido como um padrão individual de conhecimento, comportamento e reação que interagem durante a realização da tarefa, determinando a forma com que cada trabalhador se comporta frente às suas etapas. O modo operatório pode ser influenciado pela forma de treinamento, influência da gerência e complexidade da tarefa a ser realizada (FEUERSTEIN, 1996). Benchekroun (2000) realizou experimentos para identificar e analisar os diferentes estilos de execução de uma tarefa adotados pelos trabalhadores de uma indústria panificadora, concluindo que funcionários mais antigos executavam as tarefas de forma mais eficiente.

Segundo Adler e Clark (1991), componentes relacionados com o ambiente de manufatura influenciam na aquisição de conhecimento. Esses componentes são representados pelos investimentos em novas tecnologias, programas de treinamento e condições adequadas de trabalho, como estrutura e localização dos meios produtivos. A influência desses fatores sobre o aprendizado do trabalhador seria de importância equivalente ao efeito do número de repetições executadas. O modelo aditivo proposto pelos autores baseia-se no número de unidades produzidas, tempo de treinamento dos trabalhadores e tempo investido pela gerência na busca de melhorias no processo.

Vits e Gelders (2002) concluíram que a aquisição de conhecimento provém de duas correntes: conhecimento induzido e conhecimento autônomo, conforme apresentado na Figura 1. O conhecimento induzido é promovido através de meios que incentivem sua aquisição, como programas de treinamento, inovações tecnológicas e investimentos que aumentem a produção. O conhecimento autônomo é obtido através da repetição da tarefa pelo trabalhador, podendo apresentar grandes variações dentro de uma população em decorrência do desempenho particular de cada membro (FEUERSTEIN, 1996; SEREL *et al.*, 2003).

Smunt e Watts (2003) compartilham da mesma teoria, afirmando que os aprimoramentos verificados durante a execução de uma tarefa provêm do esforço repetitivo

do trabalhador e das melhorias acerca dos meios produtivos. Terwiesch e Bohn (2001) consideram o aprendizado obtido de maneira induzida mais eficiente que o obtido de forma autônoma, visto que o primeiro possui a influência da gerência e leva em consideração a adequação do trabalhador à tarefa por outros meios que não só a acumulação de unidades produzidas. Li e Rajagopalan (1997) e Terwiesch e Bohn (2001) também questionam a qualidade do aprendizado oriundo exclusivamente da repetição manual de uma tarefa, argumentando que não elucida a origem do aprendizado, nem como esse aprendizado pode ser administrado pela gerência.

Serel *et al.* (2003) formularam um modelo de investimento de recursos que associa curvas de aprendizado a variáveis que descrevem qualidade do produto. O processo de aprendizado dos trabalhadores é dissociado em aprendizado autônomo (repetições) e induzido (incentivos e treinamentos) e a qualidade dos produtos avaliada através da função perda de Taguchi (TAGUCHI *et al.*, 1990; TAGUCHI; CLAUSING, 1990, entre outros). O estudo busca estabelecer uma seqüência apropriada de investimento de recursos sobre as duas formas de aprendizado, de maneira a garantir um alto padrão de qualidade no processo e redução dos custos de não-qualidade.

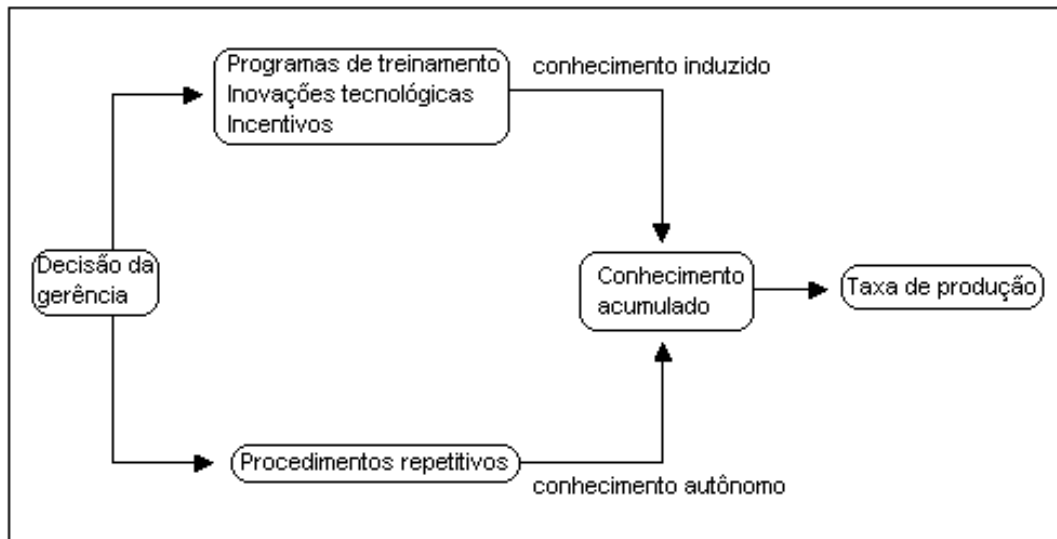


Figura 1: Esquema da aquisição de conhecimento (Adaptado de VITS; GELDERS, 2002)

Ackerman *apud* Eyring, Johnson e Francis (1993) propõem uma estrutura explicativa composta por três estágios para o processo de aquisição individual de conhecimento. Essa

estrutura possibilita a análise de características particulares do trabalhador, que lhe conferem um entrosamento mais rápido com a nova tarefa. Tais características são definidas como fatores cognitivos, os quais revelam uma facilidade particular do trabalhador em assimilar o mecanismo de execução de determinada tarefa ou etapa da mesma. Eyring, Johnson e Francis (1993) sugerem o aprimoramento da estrutura proposta por Ackerman através da inclusão de fatores como familiaridade com a tarefa e potencial de auto-avaliação, os quais influenciam de maneira determinante o processo de aprendizado.

Bandura *apud* Eyring, Johnson e Francis (1993) introduziram o conceito de auto-avaliação, definido como o reconhecimento por parte do próprio trabalhador de que a tarefa executada foi bem sucedida. Segundo Eyring, Johnson e Francis (1993), a auto-avaliação é um fator de grande importância no processo de aprendizado, pois possibilita ao trabalhador a análise de seu desempenho e a procura de meios para aprimorá-lo.

Dentro dessa mesma filosofia de aprendizado, a adoção de ciclos de aprendizado tem sido encarada como uma eficiente estrutura para a aquisição de conhecimento. Para Zangwill e Kantor (1998, 2000), cada período ou unidade fabricada é uma oportunidade para o trabalhador adquirir conhecimento e avaliar seu aprendizado, cabendo a ele impor melhorias ou modificar a maneira com que realiza a tarefa na busca de melhores resultados. Esse método teoricamente conduz a uma condição de “desperdício zero”, na qual o trabalhador gradualmente aprimora-se na execução da tarefa até a completa eliminação de falhas e movimentos desnecessários. Segundo o autor, essa é uma forma completa de aprendizagem, visto que o trabalhador pode avaliar pontos que não foram satisfatórios no ciclo anterior e realizar alterações na forma de execução para o ciclo subsequente. Outro aspecto favorável dos ciclos é sua aplicabilidade nas mais diversas naturezas de processo. Os ciclos de aprendizado também possibilitam à gerência a avaliação de medidas tomadas em um período passado e sua manutenção ou alteração para os ciclos posteriores. Para Mukherjee, Lapre e Van Wassenhove (1998), os ciclos de aprendizado podem ser divididos em duas etapas: (i) aprendizado conceitual, ou “*know why*”, onde a observação de causa e efeito gera condições de entendimento do procedimento; e (ii) aprendizado operacional, ou “*know how*”, onde se aplicam as observações conceituais e modificações necessárias, avaliando-se os resultados.

A retenção do conhecimento adquirido e o fenômeno de esquecimento também têm sido tema de estudos. Ginzburg e Dar-El (2000) realizaram pesquisas com o intuito de verificar a influência do intervalo de tempo entre treinamentos na manutenção de um patamar de desempenho satisfatório. O estudo foi conduzido com militares e englobava tarefas de alta

complexidade, sendo realizado através de simuladores. Os autores concluíram que existe um intervalo máximo entre os treinamentos que permite uma retomada integral do desempenho. A violação desses intervalos exige a adoção de outros métodos de treinamentos, visto que o desempenho ideal não pode ser mais alcançado através do treinamento convencional.

O fenômeno de esquecimento em trabalhadores pode ser definido como a queda de desempenho quantitativo e qualitativo, decorrente de fatores como aprendizado deficiente, períodos longos de inoperância ou inadequação à tarefa. Globerson, Levin e Shtub (1989) realizaram estudos (apresentados na seção 2.3.4) mostrando que o desempenho anterior à parada e o tempo de inoperância são fatores que permitem avaliar as perdas decorrentes do esquecimento.

Wickens, Gordon e Liu (1998) e Nembhard e Uzumeri (2000b) também desenvolveram estudos relacionados com a retenção de conhecimento e destreza em uma tarefa. Os resultados mostram que trabalhadores que apresentam aprendizado lento e gradual tendem a atingir um desempenho final mais elevado e mantêm esse desempenho por mais tempo, ao passo que aprendizes mais rápidos alcançam menores patamares de *performance* e apresentam um potencial de esquecimento maior (menor retenção de conhecimento).

Aprendizado lento e gradual ocorre em tarefas de natureza predominantemente repetitiva (tarefas de procedimento ou manuais), as quais possibilitam a consolidação da forma de execução da tarefa à medida que repetições são efetuadas (WICKENS; GORDON; LIU, 1998). Ao atingir-se um nível satisfatório de aprendizado, as tarefas de procedimento podem ser realizadas sem que o trabalhador direcione total atenção para seu mecanismo de execução. Nessas situações, apesar do trabalhador presumidamente deter o conhecimento integral da tarefa e suas variações, pequenas modificações na mesma exigem um período de adaptação, definido como aprimoramento psicomotor. O aprimoramento psicomotor responde pela capacidade do trabalhador em se adaptar a movimentos diferentes dos que vinham sendo realizados, ajustando-se à forma de execução do novo modelo e adquirindo destreza com o aumento de repetições (o que justifica os menores índices de desempenho verificados nos primeiros ciclos). Modificações de movimentos decorrentes da alteração de tarefas ou modelos de produtos podem ser exemplificados por diferentes aberturas da mão na realização de um movimento e diferentes velocidades para execução de determinados movimentos, entre outros (KOUBEK; LIANG, 1999; NEMBHARD; UZUMERI, 2000b).

2.3 CURVAS DE APRENDIZADO

Curvas de Aprendizado (*Learning Curves*) são representações matemáticas do desempenho de um trabalhador, quando submetido a uma tarefa manual repetitiva. À medida que repetições são efetuadas, o trabalhador demanda menos tempo para execução da tarefa, seja pela familiaridade adquirida junto aos meios de produção, adaptação às ferramentas utilizadas ou pela descoberta de atalhos para realização da mesma. As curvas também podem monitorar a redução do custo de um produto com o progresso da produção (TEPLITZ, 1991).

As curvas de aprendizado foram desenvolvidas empiricamente por Wright em 1922, através da observação da redução no custo da montagem de aviões, sendo tais dados de custos coletados durante a Primeira Guerra Mundial. Essa redução obedecia a uma taxa constante com a duplicação da quantidade de aviões produzidos, levando Wright a formular uma regra prática para a indústria aeronáutica da época, chamada de “curva de 80%”. Segundo essa regra, a montagem de determinada quantidade de aeronaves sofria redução de 20% no custo médio acumulativo a cada duplicação da quantidade produzida (WRIGHT, 1936; TEPLITZ, 1991).

A medição da *performance* do trabalhador na execução de uma tarefa pode ser feita de várias formas: (i) tempo de trabalho demandado por unidade fabricada, (ii) número de unidades fabricadas em intervalo fixo de tempo, (iii) redução dos custos do produto por unidade, (iv) porcentagem de unidades não-conformes pelo número de repetições de uma mesma operação (TEPLITZ, 1991).

A aplicação de curvas de aprendizado no monitoramento e avaliação do desempenho de trabalhadores levou ao desenvolvimento de modelos de curvas distintos. Esses modelos são constituídos por funções matemáticas de complexidades diversas, possibilitando a descrição do processo de aprendizado em diversos setores. As próximas seções trazem os fundamentos matemáticos, aplicações e limitações dos modelos de curvas de aprendizado mais difundidos na literatura.

2.3.1 Modelo Potencial (Modelo de Wright)

Conforme mencionado na seção anterior, Wright verificou um decréscimo constante no tempo e custos demandados para a execução de uma tarefa à medida que o número de

repetições dobrava. Esse decréscimo foi chamado de taxa de aperfeiçoamento do trabalhador, sendo seu complementar conhecido como taxa de aprendizado (WRIGHT, 1936). A curva de aprendizado de Wright assume uma forma potencial, conforme apresentado na equação (1). Dado seu pioneirismo, o modelo de Wright é formalmente conhecido por modelo potencial, fazendo com que outros modelos baseados em curvas dessa natureza matemática possuam denominações específicas. A Figura 2 apresenta um exemplo do gráfico do modelo de Wright.

$$A_{1 \rightarrow i} = U_1 i^b \quad (1)$$

onde:

$A_{1 \rightarrow i}$ - tempo (custo) médio demandado da primeira unidade até a i -ésima unidade (variável dependente);

U_1 - tempo (custo) demandado para fabricação da primeira unidade;

b - declividade da curva de aprendizado ($-1 \leq b \leq 0$);

i - número da repetição (variável independente).




Figura 2: Gráfico da curva de aprendizado segundo o modelo de Wright (Adaptado de JABER; BONNEY, 2001)

O parâmetro b (declividade da curva de aprendizado) é gerado por intermédio de manipulação matemática da taxa de aprendizado, sendo seu valor compreendido no intervalo -1 e 0 . Valores de b próximos da unidade negativa indicam um elevado percentual de aprendizado e assimilação rápida dos preceitos da tarefa.

Os parâmetros U_1 e b utilizados na equação (1) podem ser obtidos através de informações já coletadas do processo. Quando não se dispõe de informações prévias ou se deseja trabalhar com um produto cujo histórico não existe (novo produto), pode-se utilizar parâmetros de outros processos em que se verifique alguma semelhança com o novo produto em questão, ou recorrer a publicações que apresentem valores médios para cada tipo de produto. Com o andamento do processo, comparam-se os resultados previstos pela curva com os valores obtidos e ajustam-se os parâmetros em caso de discrepância (TEPLITZ, 1991).

A equação (1) pode ser manipulada de forma a permitir o cálculo do tempo (custo) total demandado para fabricação de i unidades ($T_{1 \rightarrow i}$) e do tempo (custo) necessário para fabricação de uma unidade específica i (U_i), conforme apresentado nas equações (2) e (3), respectivamente.

$$T_{1 \rightarrow i} = U_1 i^{b+1} \quad (2)$$

$$U_i = U_1 \left[i^{b+1} - (i-1)^{b+1} \right] \quad (3)$$

As relações de Wright [equações (1), (2) e (3)] encontram-se compiladas em tabelas baseadas no percentual de aprendizado, permitindo a obtenção dos resultados de maneira direta. Com a intenção de simplificar a utilização das curvas de aprendizado, Wright propôs gráficos em escala logarítmica, fazendo com que as curvas passassem a ser representadas por retas e a previsão de valores futuros pudesse ser retirada diretamente dos gráficos (WRIGHT, 1936; TEPLITZ, 1991).

O modelo de Crawford, a exemplo da curva proposta por Wright, também se baseou em observações na indústria aeronáutica. As verificações e conclusões dos dois modelos são bastante semelhantes, diferindo somente na conceituação dos parâmetros utilizados nas equações. Teplitz (1991) aponta como principal diferença o comportamento distinto das curvas de tempo unitário (U_i) e tempo médio ($A_{1 \rightarrow i}$) previstas pelos dois modelos, quando representadas em gráfico de escala logarítmica. A escolha do modelo, segundo o mesmo autor, depende do propósito da utilização, sendo o modelo de Wright mais aconselhado

quando se desejam valores médios de tempo para realização de uma tarefa e o modelo de Crawford quando se trabalha com valores de tempo associados a unidades específicas.

Para Blancett (2002) e Globerson e Gold (1997), a curva potencial é incontestavelmente o modelo de curva de aprendizado mais utilizado para previsão de produtividade. Segundo Vits e Gelders (2002) e Globerson e Levin (1987), a curva pode ser utilizada para descrever com boa precisão a maior parte das tarefas que se baseiam em procedimentos repetitivos, além de apresentar a vantagem de ser matematicamente simples.

2.3.1.1 Aplicações do Modelo Potencial

Curvas de aprendizado potenciais têm sido utilizadas na elaboração de estratégias de produção, estimativas de tempo para conclusão de determinadas tarefas, verificação do efeito de paradas no processo produtivo e levantamento das conseqüências de modificações nos parâmetros de um processo durante a sua execução (TOWILL, 1985; TEPLITZ, 1991). É uma ferramenta que possibilita o sequenciamento de operações dentro de um processo com maior precisão e permite uma previsão de custos nos mais diversos setores de uma empresa, incluindo *marketing*, distribuição e produção (ANDRADE *et al.*, 1999). Towill (1985) lista uma série de setores aptos à aplicação de curvas de aprendizado, abrangendo desde indústrias alimentícias até siderúrgicas.

Wright, pioneiro no desenvolvimento e utilização das curvas de aprendizado, aplicou-as no monitoramento de custos atrelados à montagem de aviões. A redução dos custos por unidade era decorrente de duas razões principais: (i) o aprimoramento dos trabalhadores nos procedimentos de montagem (redução do tempo demandado por unidade) fazia com que os custos de mão-de-obra se diluíssem em uma produção crescente; (ii) a quantidade de componentes danificados durante os procedimentos de montagem reduzia-se com o aumento da destreza dos trabalhadores, minimizando custos com material. A diluição dos *setups* das máquinas em longas corridas de produção e a adoção de ferramentas apropriadas para execução das operações também contribuíram para a redução dos custos de montagem (TEPLITZ, 1991).

Yelle (1980) sugere que a utilização de curvas de aprendizado em conjunto com o Modelo do Ciclo de Vida do Produto (descrito em COX, 1967; RINK; SWAN, 1979, entre outros) leva a um planejamento mais preciso da produção. Yelle (1983) utilizou ambos os

modelos em dados da linha de montagem do carro Ford-T, analisando a redução do valor dos custos de peças e montagem com o aumento de unidades fabricadas. Essa redução era decorrente de um maior desempenho dos trabalhadores na linha, fazendo com que os custos de mão-de-obra fossem diluídos em um maior número de carros fabricados. Paralelamente, a maior destreza adquirida pelas repetições fazia com que as montagens das peças fossem mais precisas e menos danosas, justificando a redução de custos com componentes. O autor concluiu que a utilização dos modelos em conjunto teria evitado os resultados insatisfatórios obtidos nos últimos anos de fabricação do modelo Ford-T.

O modelo proposto por Wright foi utilizado por Saraswat e Gorgone (1990) no monitoramento de equipes de trabalhadores responsáveis pela instalação de *softwares* em empresas e domicílios. A instalação de pacotes mais complexos resultou nos maiores percentuais de aprendizado (em torno de 36%), decorrentes principalmente do treinamento intensivo a que os trabalhadores eram submetidos.

Blancett (2002) aplicou curvas de aprendizado potenciais em diversos setores de uma empresa de manufatura de material de construção, abrangendo desde etapas do desenvolvimento de produto até a produção em larga escala. O horizonte de tempo utilizado para o estudo foi bastante longo, chegando a quase 3 anos. Segundo o autor, o processo de aprendizado pode ser dividido em três fases, conforme apresentado na Figura 3: (i) fase de adaptação à tarefa, onde há grande incidência de erros e baixo desempenho, (ii) fase de aprendizado efetivo, onde a *performance* do trabalhador apresenta melhorias com o progresso da produção, (iii) fase de estabilidade ou declínio, na qual não se verifica aprimoramento de desempenho e, em alguns casos, observa-se sua redução em decorrência de fadiga dos trabalhadores. Corridas curtas de produção, entretanto, impossibilitam a incursão dos trabalhadores com reduzida experiência prévia na terceira fase de aprendizado identificada por Blancett (2002), em decorrência do número limitado de unidades a serem produzidas.

Curvas de aprendizado potencial também foram utilizadas para monitorar o aprimoramento dos trabalhadores no intervalo entre o início da produção de um novo produto e a plena utilização da capacidade produtiva, período conhecido como *ramp-up*. Esse período se caracteriza por uma alta demanda, altos preços do produto em questão e uma baixa capacidade produtiva, insuficiente para atender a necessidade do mercado. Dentro desta realidade, cria-se uma grande pressão sobre os trabalhadores objetivando um rápido aprendizado, o que geralmente leva à elaboração de atalhos equivocados na execução de tarefas. Terwiesch e Bohn (2001) concluíram que programas de treinamento mais complexos

em torno do novo produto não compensam a diminuição da capacidade de produção em um momento de grande demanda. Desta forma, a curva de aprendizado possibilitou monitorar o desempenho dos trabalhadores até que um patamar considerado satisfatório fosse alcançado.




Figura 3: Etapas do aprendizado, segundo Jaber e Bonney (1999) *apud* Blancett (2002)

Buscando avaliar o potencial de aprendizado de indústrias tailandesas, Pramongkit, Shawyun e Sirinaovakul (2000) utilizaram a curva de aprendizado potencial vinculada à função de produção de Cobb-Douglas, apresentada na equação (4). A relação resultante, apresentada na equação (5), permitiu analisar a importância de fatores como capital investido e quantidade de mão-de-obra especializada empregada no aprendizado dos trabalhadores. As indústrias classificadas como pesadas (grande investimento inicial) apresentaram os melhores índices de aprendizado, mostrando-se mais propícias para o investimento de recursos do que as pequenas empresas.

$$Q = AL^{\beta} K^{\gamma} \quad (4)$$

onde:

Q - quantidade total produzida;

A - parâmetro que descreve o progresso do desempenho (dependente de X_t , apresentado abaixo);

L - mão-de-obra empregada;

K - valor de estoque utilizado para produção de Q ;

β e γ - parâmetros de elasticidade relacionados à mão-de-obra e aos recursos capitais, respectivamente.

$$\ln(L/Q)_t = -\ln H - \alpha \ln X_t + (1 - \beta) \ln L_t - \gamma \ln K_t \quad (5)$$

onde:

H - constante de proporcionalidade;

X_t - número de unidades fabricadas no período t ;

α - declividade de aprendizado.

Em estudo posterior, Pramongkit, Shawyun e Sirinaovakul (2002) aplicaram curvas de aprendizado em conjunto com um indicador de crescimento tecnológico e produtivo (*Total Factor Productivity* - TFP). Tal aplicação possibilitou analisar a influência do grau de desenvolvimento tecnológico de grandes empresas tailandesas sobre o potencial de aprendizado dos trabalhadores. Os autores verificaram que trabalhadores de empresas tidas como detentoras de maior tecnologia atingiam maiores percentuais de aprendizado.

A programação de produção também pode ser auxiliada por curvas de aprendizado. Segundo Salameh, Abdul-Malak e Jaber (1993) e Jaber e Bonney (1999), equações para obtenção do lote ótimo de produção são desenvolvidas sob a condição de taxa constante de produção. Entretanto, situações em que o trabalhador passa a operar com novos produtos ou depois de um período de inoperância invalidam a consideração de taxa constante, visto que o desempenho dos trabalhadores aprimora-se com o decorrer do processo. Keachie e Fontana *apud* Jaber e Bonney (1999) desenvolveram uma equação para obtenção do tamanho de lotes

de produção em situações em que se verifica aprendizado, utilizando a função de estimação do custo total de estoque. Muth e Spremann (1983) aprimoraram a relação proposta por Keachie e Fontana, chegando à equação transcendental (7), cuja solução é obtida através de iterações numéricas. Steedman *apud* Jaber e Bonney (1999) realizou pesquisas comparativas entre a tradicional equação de determinação do tamanho do lote ótimo e a equação que incorpora o parâmetro de aprendizado [equações (6) e (7), respectivamente], sendo que a última resulta em lotes de maior tamanho. No mesmo estudo, Steedman verificou que o aumento da declividade de aprendizado (b) na equação (7) resulta em lotes ótimos de menor tamanho.

$$q_0 = \sqrt{\frac{2rC_S}{C_C}} \quad (6)$$

onde:

q_0 – tamanho ótimo do lote, em unidades;

r – demanda média anual;

C_C – custo de material por item;

C_S – custo de *set-up*.

$$q^* \approx \sqrt{\frac{2r}{C_C} \left[C_S + \frac{C_1 T_1 q_0^{1-b}}{2} \right]} \quad (7)$$

onde:

q^* - tamanho ótimo do lote na presença de aprendizado;

C_1 – custo de mão-de-obra por item;

T_1 – desempenho na fabricação da 1ª unidade;

b – declividade de aprendizado.

Salameh, Abdul-Malak e Jaber (1993) desenvolveram um método simplificado para analisar a influência do aprendizado sobre o tamanho do lote ótimo de produção e custo de estoque. O método incorpora a curva de aprendizado potencial nas expressões para obtenção do custo de produção. O aprimoramento do desempenho dos trabalhadores reduz o tempo necessário para conclusão de um lote, resultando em redução dos custos de produção e do tamanho do lote ótimo. A pequena retração do custo médio de estoque justifica-se pelo menor tempo de permanência do produto em estoque, tendo em vista a diminuição do tempo necessário para produção do lote.

Em estudo similar, Jaber e Bonney (2001) analisaram a magnitude das alterações no tamanho do lote ideal e nos custos de estoque decorrentes do aprendizado no processo de produção. O tamanho dos lotes apresenta redução devido ao aprimoramento dos trabalhadores na execução da tarefa, sugerindo que a produção deveria adotar bateladas de menor tamanho e com operação mais freqüente. Os custos de estoque, entretanto, não foram significativamente afetados pela consideração de aprendizado, levando os autores a discordar das verificações de Salameh, Abdul-Malak e Jaber (1993) nesse aspecto e concluir que modificações no tamanho dos lotes decorrentes de aprimoramento não causam variações significativas nos custos de estoque.

Buscando vincular a curva de aprendizado a ferramentas para controle de qualidade, Franceschini e Galetto (2002) propuseram um método para obtenção de uma estimativa preliminar da redução do percentual de produtos não conformes em uma planta de produção de suco. Um modelo de curva de aprendizado potencial foi utilizado em conjunto com uma carta de controle p , possibilitando a construção de limites de controle para o monitoramento da variabilidade de não conformes. Aprimoramentos no processo reduzem a distância entre os limites de controle superior e inferior, indicando redução na variabilidade do processo, enquanto que o aprimoramento do desempenho dos trabalhadores leva a uma redução do percentual de defeituosos.

Curvas de aprendizado também podem ser utilizadas no setor de serviços. Chambers e Johnston (2000) aplicaram a ferramenta em duas fornecedoras de serviços: uma grande empresa de transporte aéreo e uma pequena instituição bancária. Segundo os autores, a padronização de etapas da tarefa e a baixa customização são requisitos para a aplicação das curvas no setor de serviços. No caso da companhia aérea, verificou-se uma perda de desempenho dos funcionários durante os vinte anos de duração do estudo, decorrentes principalmente do processo de privatização atravessado pela companhia. Essa perda foi

justificada pela mudança na padronização de tarefas, as quais foram remodeladas devido às novas diretrizes da empresa. A utilização das curvas na instituição bancária foi breve e mais simples. Pelo fato das tarefas serem padronizadas, verificou-se redução de 30% no tempo demandado para execução das tarefas, considerado um resultado altamente satisfatório.

2.3.1.2 Limitações e Modificações do Modelo Potencial

Por se tratar do modelo mais simples e difundido entre as curvas de aprendizado, a curva potencial tem sido matéria de estudos, principalmente no que se refere às suas limitações e adaptações para cenários específicos (ZANGWILL; KANTOR, 1998). As adaptações buscam a eliminação de inconsistências decorrentes da simplicidade matemática da equação potencial.

Hurley (1996) alega que o modelo proposto por Wright, quando utilizado em ciclos longos de produção, resulta em previsões de tempo para execução da tarefa próximas a zero, o que não se verifica na prática. Eden, Willians e Ackermann (1998) sugerem a inclusão de um parâmetro definido como “tempo padrão” (T_s) na equação (1), valor para o qual o desempenho converge quando o número de repetições é elevado. O valor de T_s é determinado experimentalmente levando em consideração as características de cada atividade e representa o tempo demandado para execução da tarefa quando o estado estacionário é atingido. O modelo do “Plateau” (apresentado na seção 2.3.2.4) também é baseado na inclusão de uma constante e indicado para o monitoramento de corridas longas de produção.

Segundo Garg e Miliman *apud* Globerson, Levin e Shtub (1989), o modelo de Wright não faz referência à experiência anterior do trabalhador em uma operação, fator que determina um rendimento superior deste trabalhador em relação a outro que nunca executou a mesma operação. O modelo de Stanford-B (apresentado na seção 2.3.2.1) foi desenvolvido para preencher essa lacuna.

Devido a sua larga utilização como ferramenta de previsão, as curvas de aprendizado têm dado margem a definições alternativas e dependentes do contexto de aplicação. Segundo Towill (1985, 1990), a utilização de tempo demandado por unidade como variável descritiva do desempenho caracteriza uma “função de progresso”, enquanto que medições de taxas de produção (unidades produzidas por intervalo de tempo) são definidas como curvas de

aprendizado. Para Hill *apud* Towill (1990), quando se avalia o custo de produção, a curva é identificada como “curva de experiência”.

Segundo Teplitz (1991), a modelagem por curvas de aprendizado gera parâmetros específicos, como declividade de aprendizado e experiência anterior, os quais permitem descrever e analisar o processo de aprendizado e fazer estimativas em torno de produções futuras. Curvas de produtividade fazem uso das taxas de produção como variável de análise e decisão. Funções de progresso de manufatura monitoram a redução de custo como função do aumento de experiência do trabalhador.

Aplicações com conceitos equivocados podem comprometer a capacidade preditiva da curva de aprendizado. Towill (1990) e Waterworth (2000) alertam para a distinção entre tempo acumulativo médio para realização de um número determinado de repetições e tempo demandado para execução de uma repetição específica. Muitas aplicações fazem uso dos dois conceitos para a descrição da mesma situação, apesar de haver diferenças entre os valores preditos superiores a 30% em alguns casos.

Com o propósito de reduzir o equívoco acima mencionado em casos de produção em bateladas, Smunt (1999) sugere uma interpretação alternativa para o conceito de repetição. As repetições passariam a ser computadas como metade do número de unidades componentes da batelada (repetição $i/2$, no caso de bateladas com i unidades). Essa forma de representação é justificada pela Teoria de Aprendizado Contínuo proposta por Smunt (1999), segundo a qual o aprendizado ocorre durante a execução da repetição e não quando a repetição foi concluída. A interpretação sugerida é útil para predições sobre bateladas em que não se dispõe da totalidade de dados de desempenho relativos aos seus i componentes.

A variabilidade dos dados de desempenho provenientes dos processos pode gerar curvas com ajuste deficiente e baixo poder preditivo. A curva de aprendizado é suscetível à natureza estocástica dos dados que originam seus parâmetros, o que pode comprometer sua capacidade preditiva (YELLE, 1979). Globerson (1984), verificando o desvio existente entre os valores previstos por uma curva potencial e os valores obtidos na execução posterior da tarefa, apontou a declividade de aprendizado (parâmetro b) mal estimada como principal causadora de discrepâncias. O autor desenvolveu um modelo que gera intervalos de confiança em torno dos tempos previstos para execução da tarefa. Globerson e Gold (1997), considerando a aquisição de conhecimento como um processo sujeito a grande variabilidade, desenvolveram expressões para obtenção da variância, coeficiente de variação e função densidade de probabilidade do desempenho predito a partir da curva de aprendizado potencial.

Vigil e Sarper (1994) também desenvolveram estudos relativos aos efeitos da variabilidade dos dados que dão origem aos parâmetros da curva de aprendizado. Os autores afirmam que os desvios entre os valores preditos pela curva e os resultados verificados na prática provêm de parâmetros de declividade de curva (b) mal estimados, principalmente quando não se dispõe de informações acerca de um novo produto. Paralelamente, os autores observaram uma forte correlação entre o parâmetro b e o valor de tempo (custo) demandado na execução da primeira unidade a ser produzida, levando-os a desenvolver uma equação relacionando os dois parâmetros, apresentada na equação (8). Segundo os autores, o tempo demandado para a execução da primeira unidade (A) fornece uma estimativa preliminar do aprimoramento que pode ser obtido com o transcorrer do processo, justificando a correlação com o parâmetro b . Essa estimativa, contudo, deve ser utilizada com cautela nos primeiros ciclos de produção e ajustada em caso de desvios elevados.

$$\log b = \log M + N \log A \quad (8)$$

onde:

b - declividade estimada de aprendizado;

A - tempo (custo) da primeira unidade;

M e N - constantes.

Smunt (1999) sugere uma modificação no modelo potencial com o propósito de adaptar a curva de aprendizado a situações onde se verificam alterações no valor da declividade de aprendizado dentro de um mesmo processo, principalmente em operações com bateladas. O modelo realiza o somatório de i curvas de aprendizado (referentes a i bateladas sequenciais que compõem o processo), cada qual com seu valor específico de declividade (b_i), possibilitando a determinação do tempo total demandado para conclusão do processo.

Smunt e Watts (2003) propuseram técnicas de agregação dos dados obtidos do processo capazes de reduzir a variância dos mesmos e conduzir a previsões mais confiáveis. Intervalos de tempo foram somados de forma a gerar intervalos de maior duração, reduzindo a variabilidade dos dados de desempenho. A modelagem dos dados agregados resultou em

coeficiente de determinação mais elevado, se comparado com o obtido na modelagem dos dados originais.

A utilização do número de unidades produzidas como única variável independente para o monitoramento do progresso de trabalhadores em uma tarefa tem gerado questionamentos quanto à eficiência dos modelos de aprendizado. Fine (1986) argumenta que unidades acumulativas podem esconder falhas graves no processo de aprendizado, pois não avaliam a qualidade da unidade produzida. O autor desenvolveu uma curva de aprendizado onde somente as unidades consideradas conformes com as especificações de projeto compõem a variável independente. Li e Rajagopalan (1997) ampliaram a curva proposta por Fine (1986), utilizando tanto o número de unidades conformes como o de não-conformes para o monitoramento do processo de aprendizado. A relação é apresentada na equação (9), sendo que a soma das unidades conformes e não-conformes corresponde ao número total de unidades produzidas.

$$\ln H_t = \theta_0 + \theta_1 \ln(\sigma D_t + \pi N_t) + \theta_2 \ln P_t + \varepsilon_t \quad (9)$$

onde:

H_t - desempenho no período t (tempo/unidade);

θ_0 - desempenho na 1ª unidade (tempo/unidade);

θ_1 - declividade de aprendizado (similar a b);

σ - proporção de unidades não-conformes sobre a produção total;

D_t - número acumulativo de unidades não-conformes;

π - proporção de unidades conformes sobre a produção total;

N_t - número acumulativo de unidades conformes;

θ_2 - parâmetro de efeito da economia de escala;

P_t - número de unidades produzidas no período t ;

ε_t - parâmetro de desvio (normalmente distribuído e com variância constante).

Segundo experimentos, o efeito da inclusão de variáveis que quantifiquem o número de unidades conformes e não-conformes no modelo de aprendizado é significativo na descrição do aprendizado dos trabalhadores. Li e Rajagopalan (1997) verificaram que a produção de unidades não-conformes é mais eficiente para a assimilação de conhecimento, visto que incentiva o entendimento mais profundo do processo e gera oportunidades de aprimoramento pela eliminação das causas da não-qualidade. A ocorrência de unidades de baixa qualidade nos primeiros ciclos deve ser avaliada quanto as suas causas, permitindo modificações na forma de execução da tarefa que irão garantir índices satisfatórios de qualidade em produções futuras.

2.3.2 Demais Modelos de Curvas de Aprendizado de Natureza Potencial

Alguns modelos de curvas de aprendizado foram desenvolvidos através de modificações e adaptações no modelo potencial proposto por Wright, visando sua utilização em cenários específicos. Tais modelos passaram a ser conhecidos por definições distintas, sendo apresentados na seqüência.

2.3.2.1 Modelo de Stanford-B

O modelo de Stanford-B foi desenvolvido com o propósito de incorporar a experiência prévia do trabalhador ao modelo sugerido por Wright. A experiência prévia é quantificada pelo parâmetro B , apresentado na equação (10). A função de B é deslocar o desempenho do trabalhador a patamares mais elevados através da sua inclusão no número de unidades produzidas (TEPLITZ, 1991).

$$y = C_1(x + B)^b \quad (10)$$

onde:

y - desempenho acumulativo médio (custo) na execução da unidade x ;

C_1 - desempenho (custo) da primeira unidade de produção;

b - declividade de aprendizado ($-1 < b < 0$);

B - número de unidades equivalentes à experiência prévia (ou valor de escala, conforme Badiru, 1992).

Badiru (1992) sugere que o parâmetro B obedeça a uma escala de 1 a 10 (maior valor equivalente a maior experiência prévia), definida pelas características da tarefa. Quando $B=0$, não existe experiência anterior e o modelo de Stanford-B se reduz à equação de Wright.

O modelo de Stanford-B foi utilizado em etapas da fabricação do Boeing 707, conduzindo aos melhores resultados entre os modelos de curvas testados (BADIRU, 1992; NEMBHARD; UZUMERI, 2000a). Posteriormente, uma versão modificada do modelo foi utilizada para incorporar alterações na estrutura da aeronave (YELLE, 1979).

2.3.2.2 Modelo de DeJong

O modelo de DeJong permite descrever processos onde tarefas manuais são alternadas com operações realizadas por máquinas. A principal característica destes processos é o baixo potencial de diminuição do tempo necessário para a execução da tarefa, visto que somente os procedimentos manuais são passíveis de redução de tempo. Operadores que executam tais tarefas atingem rapidamente o estado estacionário (YELLE, 1979; TEPLITZ, 1991). Estudos empíricos conduzidos por Hirsch *apud* Yelle (1979) mostram que a taxa de aprendizado de trabalhadores ligados a tarefas exclusivamente manuais é duas vezes maior que a taxa apresentada por trabalhadores submetidos a trabalhos com máquinas.

O modelo de DeJong é apresentado na equação (11). A proporção da tarefa executada por máquinas é representada pelo parâmetro M (fator de incompressibilidade), compreendido entre 0 e 1. O valor de M é dado pela proporção do tempo total da tarefa constituído de procedimentos automatizados. Quando M assume valor zero, não existe participação de maquinário no processo e o modelo se reduz à tradicional equação de Wright. No caso de $M = 1$, o processo é integralmente controlado por máquinas, não sendo possível compressão do tempo demandado para realização das tarefas. Processos totalmente automatizados são exemplos dessa condição (BADIRU, 1992).

$$y = C_1[M + (1 - M)x^b] \quad (11)$$

onde:

y - desempenho acumulativo médio (custo) na execução da unidade x ;

C_1 - desempenho (custo) da primeira unidade produzida;

b - declividade de aprendizado ($-1 < b < 0$);

M - fator de incompressibilidade ($0 < M < 1$).

2.3.2.3 Curva “S”

O modelo de curva de aprendizado “S” foi desenvolvido para monitorar o desempenho dos trabalhadores nas primeiras unidades de uma corrida de produção com maior precisão. A curva “S” assume um aprendizado mais lento e gradual nas primeiras unidades (1ª etapa do aprendizado), decorrente de um processo de adequação dos trabalhadores às novas ferramentas e procedimentos. A 2ª etapa do processo representa o período de aprendizado efetivo, onde se verifica aprimoramento na execução da tarefa. Na 3ª etapa ocorre a estabilização do desempenho, onde o aprendizado está consolidado (TEPLITZ, 1991). As três etapas podem ser visualizadas na Figura 3.

A curva “S” foi desenvolvida através da união dos modelos de DeJong e Stanford-B, sendo representada pela equação (12). Os quatro parâmetros da curva assumem o mesmo significado dos dois modelos em que foi baseada. Sua aplicação contempla tarefas que necessitam da intervenção de máquinas e cuja análise do desempenho nas primeiras unidades assume importância para descrição do processo (BADIRU, 1992; NEMBHARD; UZUMERI, 2000a).

$$y = C_1 [M + (1 - M)(x + B)^b] \quad (12)$$

2.3.2.4 Modelo de Plateau

O Modelo de Plateau foi desenvolvido para monitorar o desempenho do trabalhador quando o volume de produção é elevado. Nessa condição, o processo de aprendizado pode ser dividido em duas etapas: (i) etapa de aprendizado efetivo; (ii) etapa onde o trabalhador

atinge um estado estacionário de desempenho (plateau). Uma possível explicação para o aparecimento do plateau é a conclusão do processo de aprendizado na tarefa ou alguma limitação imposta pelo maquinário ao progresso do trabalhador na execução da tarefa (TEPLITZ, 1991; LI; RAJAGOPALAN, 1998).

O modelo consiste na inclusão de uma constante aditiva no modelo proposto por Wright [equação (1)]. O desempenho assume o valor dessa constante quando o número de repetições for elevado, ou seja, o estado estacionário é atingido, contornando a inconsistência do Modelo de Wright que prevê valores de tempo demandado por unidade próximos a zero nessa situação. A constante é estimada através da análise do tempo padrão para a execução da tarefa (YELLE, 1979; TEPLITZ, 1991).

Li e Rajagopalan (1998) afirmam que o estado estacionário atingido é decorrente de um equilíbrio entre a taxa de aprendizado e a taxa de depreciação de conhecimento, fazendo com que o desempenho do trabalhador permaneça constante. Existem, segundo os autores, formas de aquisição de conhecimento ótimas para a chegada ao estado estacionário, as quais podem ser modeladas através de combinações entre atividades de aprendizado autônomas e induzidas.

A Figura 4 permite a comparação entre os perfis gerados pelos modelos de natureza potencial apresentados nessa seção, cuja unidade de desempenho é medida em tempo demandado por unidade fabricada.




Figura 4 : Comparação dos modelos de curva de aprendizagem de natureza potencial em escala logarítmica (Adaptado de BADIRU, 1992)

2.3.3 Modelos Exponenciais

A maioria das teorias que buscam a explicação e descrição do processo de aprendizado baseia-se no princípio de substituição, ou seja, um procedimento executado de forma incorreta é substituído por outro executado de maneira correta com o decorrer das repetições (RESTLE; GREENO *apud* MAZUR; HASTIE, 1978). Curvas de natureza potencial (vistas anteriormente) e de natureza exponencial [exemplificada na equação (13)] descrevem esse processo de aprendizado com boa precisão. Os parâmetros k , p e r da equação exponencial são obtidos através de regressão e a aderência da curva pode ser avaliada por meio da soma dos erros quadrados entre os valores preditos e os observados (MAZUR e HASTIE, 1978).

$$y = k(1 - e^{-\frac{(x+p)}{r}}) \quad (13)$$

onde:

y - medida do desempenho do trabalhador em unidades/tempo;

k - desempenho limite quando aprendizado for integral (mesma unidade de y);

x - número de unidades executadas ou intervalos de tempos trabalhados;

r - velocidade de aprimoramento de desempenho (mesma unidade de x);

p - número de unidades acumulativas que quantificam a experiência prévia do trabalhador, caso exista.

O modelo exponencial é constituído por parâmetros que permitem extrair maior quantidade de informação que a disponibilizada pelos modelos potenciais. A convergência do modelo em determinados casos, entretanto, é inferior quando comparada com a obtida pelas curvas potenciais na modelagem de dados similares (NEMBHARD; UZUMERI, 2000a). Isso se deve à maior quantidade de parâmetros existentes no modelo exponencial e a particularidades dessa natureza de curva.

Os perfis gerados pelo modelo exponencial são crescentes, sendo o desempenho medido em número de unidades por tempo de operação. Os modelos de curvas de aprendizado potencial são fundamentados na medição do tempo demandado por unidade produzida, resultando em perfis de aprendizado decrescentes.

Estudos realizados por Mazur e Hastie (1978) mostram que a equação (13) resulta em modelagens deficientes quando o trabalhador analisado é submetido a tarefas complexas e que demandam grande quantidade de novos conhecimentos. Em contrapartida, gera bons resultados em situações em que o trabalhador apresenta experiência prévia.

Towill (1990) desenvolveu uma equação exponencial de estrutura semelhante à proposta por Mazur e Hastie (1978), denominada Modelo de Tempo Constante [equação (14)]. O modelo utiliza o tempo acumulativo de trabalho (t) como variável independente, sendo seu significado idêntico ao número de unidades produzidas (x) adotado pelos demais modelos de curvas. Essa adaptação possibilita a determinação simplificada do tempo demandado para a obtenção de determinado patamar de desempenho. Naim e Towill (1990) avaliaram o Modelo de Tempo Constante como uma ferramenta apropriada para descrição do aprimoramento de trabalhadores, dada sua aplicabilidade em tarefas de naturezas diversas. O modelo pode ser combinado com funções trigonométricas, sendo útil em situações onde há alternância entre tendência contínua de aprimoramento e variações cíclicas de desempenho decorrentes de fatores conhecidos.

$$y = y_c + y_f(1 - e^{-t/\tau}) \quad (14)$$

onde:

y - desempenho do trabalhador no instante t de operação (unidades/tempo);

y_c - desempenho inicial (unidades/tempo);

y_f - aprimoramento máximo de desempenho (unidades/tempo);

t - tempo de atuação na operação;

τ - parâmetro constante de tempo (atua como parâmetro de forma da curva).

A equação (14) prevê um aumento no desempenho y à medida em que o tempo t de atuação do trabalhador cresce, sendo a intensidade deste crescimento dependente do parâmetro y_f . Segundo Towill (1990), o modelo é recomendado para situações em que a coleta de dados de desempenho se inicia depois de um pequeno período de adaptação do trabalhador à tarefa.

Knecht *apud* Nembhard e Uzumeri (2000a) propôs um modelo distinto formado pela combinação das equações potencial e exponencial. O modelo apresenta boa aderência a dados experimentais de operações em que a declividade de aprendizado não se mantém constante durante o transcorrer do processo. Esse comportamento é característico de corridas longas de produção. Nembhard e Uzumeri (2000a), entretanto, consideram os parâmetros do modelo pouco claros na explicação do processo de aprendizado, o que limita sua capacidade como ferramenta preditiva.

Curvas de aprendizado exponenciais podem ser utilizadas em conjunto com ferramentas voltadas para o aprimoramento da qualidade em processos produtivos, dentre elas a manutenção total da produção (*Total Productive Maintenance* - TPM). Wang e Lee (2001) utilizaram o Modelo de Tempo Constante e ferramentas de regressão linear para determinar a taxa de aprimoramento dos trabalhadores em função de variáveis pouco usadas até então, como o tamanho da companhia, grau de vendas e existência ou não de certificação ISO. Esse modelo foi aplicado em indústrias do Japão e Taiwan e permitiu a determinação do momento apropriado para a inserção do TPM na empresa e o monitoramento dos seus resultados sobre o desempenho dos trabalhadores. A curva de aprendizado também apontou aspectos comuns e divergentes das indústrias dos dois países.

2.3.4 Modelos Hiperbólicos

Thurstone *apud* Mazur e Hastie (1978) propôs uma formulação na qual o processo de aquisição de conhecimento obedeceria a um mecanismo acumulativo, onde o número de unidades ou horas executadas de maneira errônea seriam computadas e utilizadas na determinação do desempenho do trabalhador. As unidades ou horas executadas de maneira correta passariam a se acumular com o transcorrer da tarefa, aumentando sua proporção em relação às unidades produzidas de forma equivocada. A forma matemática sugerida consistiu em uma curva hiperbólica de dois parâmetros [apresentada na equação (15)]. Uma análise preliminar da equação segundo seus princípios de concepção permite conciliar a variável x ao número de unidades executadas de maneira correta; r ao número de unidades equivocadas e y à proporção de unidades consideradas corretas.

$$y = k \left(\frac{x}{x+r} \right) \quad (15)$$

Para fins de modelagem do desempenho de trabalhadores, os parâmetros na equação (15) apresentam significado semelhante aos da equação (13), onde a variável de resposta y (ordenada do gráfico apresentado na Figura 5) representa o desempenho do trabalhador em determinada tarefa após x unidades acumuladas, sendo sua unidade a mais conveniente para a descrição do processo. A variável y , a exemplo do modelo exponencial, descreve o número de unidades produzidas em um determinado intervalo de tempo fixo, o que permite verificar o andamento do processo no tempo (MAZUR; HASTIE, 1978). y também pode ser representada através de escalas padronizadas de desempenho definidas pela empresa (UZUMERI; NEMBHARD, 1998).

O parâmetro x (abscissa do gráfico apresentado na Figura 5) representa o número de unidades transcorridas e assume a unidade mais conveniente para descrição do processo, podendo, por exemplo, ser descrito como unidades produzidas ou tempo de operação. A unidade de x deve ser mantida inalterada para todos os indivíduos da população a serem modelados. O parâmetro k representa um patamar máximo de desempenho a ser atingido quando a aquisição de conhecimento for integral e r representa o número de unidades x (ou

tempo de operação) necessárias para atingir $k/2$, que corresponde à metade do patamar de desempenho máximo (UZUMERI; NEMBHARD, 1998).


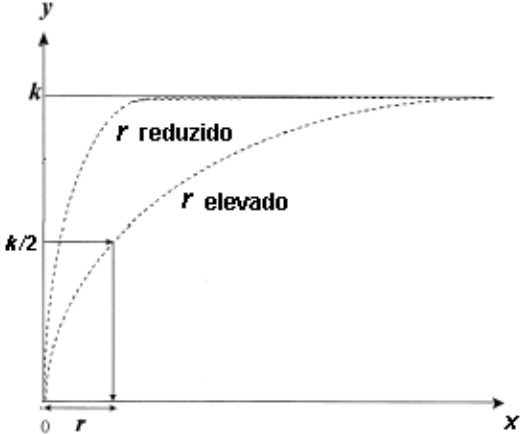
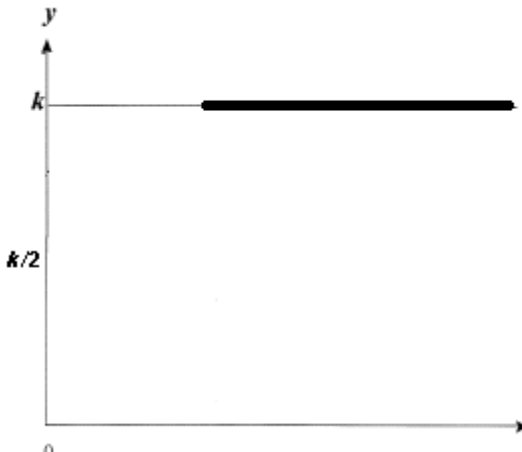
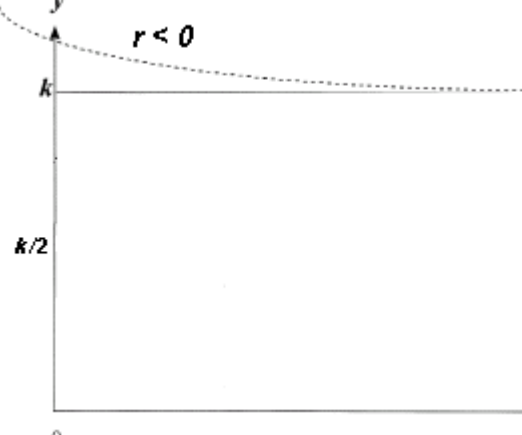


Figura 5: Representação gráfica das equações hiperbólicas (15) e (16) (Adaptado de UZUMERI; NEMBHARD, 1998)

Os parâmetros k e r variam de forma independente para cada trabalhador modelado. O parâmetro r pode ser interpretado como a taxa de aprimoramento de desempenho do trabalhador em direção ao patamar k e atua como parâmetro de forma da equação hiperbólica, podendo descrever três padrões diferentes de aprendizado. Os padrões são: (i) $r > 0$, a curva cresce até um valor limite de desempenho k . A velocidade de crescimento da curva é mais elevada quando r apresenta baixos valores, ou seja, são necessárias poucas repetições (ou menor tempo de operação) para que o patamar $k/2$ seja alcançado. Situações de aprendizado onde $r > 0$ são exemplificadas por trabalhadores com reduzida experiência prévia submetidos a novas tarefas; (ii) $r \rightarrow 0$ e presença de experiência prévia, situação na qual a curva comporta-se como uma linha horizontal, descrevendo um processo onde não há aprendizado; (iii) $r < 0$, verificado em situações onde o desempenho diminui com o transcorrer do processo, sendo representado por uma curva decrescente. Esse caso indica a ocorrência de queda de desempenho, seja por fadiga ou por esquecimento quanto à tarefa (UZUMERI; NEMBHARD, 1998). O Quadro 1 apresenta as características e o comportamento dos perfis em função do parâmetro r .

MÓDULO DE r	VERIFICAÇÕES	PERFIL DA CURVA
$r > 0$	<ul style="list-style-type: none"> • Aprimoramento de desempenho • Trabalhador assimilando novos conceitos, aprimorando destreza ou readaptando-se a uma tarefa conhecida • Valores reduzidos de r levam a crescimento mais acentuado do desempenho 	
$r = 0$	<ul style="list-style-type: none"> • Desempenho estacionário • Presença de experiência prévia 	
$r < 0$	<ul style="list-style-type: none"> • Redução de desempenho • Verificação de fadiga ou modificações equivocadas nos procedimentos de produção 	

Quadro 1: Características e perfis das curvas em função do parâmetro r

Kientzle *apud* Mazur e Hastie (1978) verificou a necessidade de inclusão de um terceiro parâmetro na equação (15) para representação da experiência prévia (p), visto que a equação hiperbólica de dois parâmetros (k e r) assume a inexistência de conhecimento na

partida do processo, situação que não é verdadeira quando os trabalhadores já executaram tarefas similares. O parâmetro p possui a mesma unidade de x , indicando o número de unidades (repetições) a que equivale a experiência do trabalhador que já executou a tarefa em questão (ou tarefa similar) em algum instante passado. Sua função é deslocar artificialmente o desempenho a patamares mais elevados através do ajuste no número de unidades produzidas. A equação hiperbólica de três parâmetros é apresentada na equação (16).

$$y = k \left(\frac{x + p}{x + p + r} \right) \quad (16)$$

$$y, k, p, x \geq 0 \quad e \quad p + r > 0$$

O denominador da equação (16) ($x+p+r$) deve ser diferente de zero para evitar a divisão por zero. Considerando que o número de unidades acumuladas é sempre positivo, é necessário que $p > -r$ (NEMBARD; UZUMERI, 2000a).

A equação (16) possibilita a modelagem de casos onde se verifica aprendizado positivo (aquisição de conhecimento) e aprendizado negativo (qualquer forma de diminuição de desempenho), sendo esse último caso modelado por um número limitado de modelos de curvas. Segundo Nembhard e Uzumeri (2000a), os pré-requisitos matemáticos para que uma equação seja capaz de modelar casos de aprendizado negativo são os seguintes: (i) $(\partial y / \partial x) < 0$, significando que a função que descreve o desempenho é decrescente; (ii) $(\partial^2 y / \partial x^2) > 0$, ou seja, a velocidade de declínio da função reduz-se com o aumento de x ; e (iii) a função converge para um patamar de desempenho k positivo, ou seja, $0 < \lim_{x \rightarrow \infty} y < \infty$.

As derivadas primeira e segunda da equação (16) são $(\partial y / \partial x) = kr / (x+p+r)^2$ e $(\partial^2 y / \partial x^2) = -2kr / (x+p+r)^3$. Segundo os critérios apresentados por Nembhard e Uzumeri (2000a), a equação hiperbólica de 3 parâmetros se comporta da seguinte maneira ao descrever casos de aprendizado positivo: (i) $(\partial y / \partial x) > 0$; (ii) $(\partial^2 y / \partial x^2) < 0$; (iii) $k > 0$ e $r > 0$. Para casos em que se verifica aprendizado negativo, ou queda de desempenho: (i) $(\partial y / \partial x) < 0$; (ii) $(\partial^2 y / \partial x^2) > 0$; (iii) $k > 0$ e $r < 0$. Assim, o sinal do parâmetro r indica se a curva descreve uma situação de aprendizado positivo ou negativo. Os perfis gerados pela equação (16), bem como a influência do parâmetro p , podem ser visualizados na Figura 5.

A similaridade na interpretação dos parâmetros k , r e p das equações (13) e (16) levou Mazur e Hastie (1978) a desenvolver uma série de experimentos buscando comparar os resultados previstos pelos modelos exponencial e hiperbólico. Os estudos foram realizados em diversas áreas, abrangendo atividades de memorização (aprendizado cognitivo) e execução de tarefas manuais (aprendizado psicomotor), nas quais avaliava-se a adaptação do trabalhador a tarefas que demandavam destreza. Utilizou-se a soma dos desvios quadrados entre os dados coletados e os preditos como critério para avaliar a aderência de cada modelo (MAZUR; HASTIE, 1978).

Os parâmetros r e p gerados pelas equações (13) e (16) apresentaram grandezas similares. As maiores diferenças foram verificadas no valor de desempenho final (k) estipulado pelas equações. De maneira geral, o modelo exponencial subestima o parâmetro k , levando a previsões de desempenho inferiores aos valores verificados em aplicações práticas. O modelo acumulativo forneceu valores de k próximo aos verificados nos experimentos, além de oferecer melhores ajustes aos dados experimentais. Mazur e Hastie (1978) concluíram que o modelo hiperbólico de 3 parâmetros mostrou-se eficiente para modelar qualquer seqüência de etapas de operações, sendo superior ao modelo exponencial em vários aspectos e possibilitando averiguar de maneira bastante precisa o desempenho do trabalhador.

Frente aos bons resultados gerados pelo modelo hiperbólico de três parâmetros, Uzumeri e Nembhard (1998) sugeriram sua utilização para descrever o perfil de aprendizado de uma população de trabalhadores submetidos a novas tarefas. Segundo os autores, a utilização de um único modelo de curva de aprendizado possibilita conclusões mais precisas quanto ao comportamento global da mão-de-obra, visto que as análises tradicionais empregam vários modelos de curvas ajustadas a situações específicas ou a determinados grupos de trabalhadores. A adoção de vários modelos de curvas para caracterizar grupos específicos de uma mesma população impossibilita a comparação direta do desempenho desses grupos, visto que os parâmetros de cada modelo se fundamentam em preceitos teóricos distintos.

A existência de uma ferramenta simples e eficiente para caracterização de uma população de trabalhadores, segundo seu potencial de aprendizado, se constitui em um recurso de elevada aplicabilidade. Segundo Argote, Beckman e Epple (1990), a análise do potencial de aprendizado e retenção de conhecimento de membros de uma população de trabalhadores permite tomar decisões adequadas quanto a sua alocação em determinadas tarefas.

O experimento realizado por Uzumeri e Nembhard (1998) para avaliação do potencial preditivo do modelo hiperbólico de 3 parâmetros consistiu no monitoramento do desempenho de trabalhadores em procedimentos de montagem. Os parâmetros gerados pelas modelagens através da equação (16) possibilitaram a caracterização de cada trabalhador segundo seu patamar de desempenho final (k), experiência prévia (p) e rapidez de aprendizado (r).

Os parâmetros permitiram a construção de um gráfico tridimensional capaz de resumir o desempenho de cada trabalhador a um ponto no espaço definido por k , p e r , gerando uma espécie de “mapa” de desempenho do aprendizado organizacional do grupo analisado. O gráfico é apresentado na Figura 6. Os parâmetros p e r foram expressos em logaritmo [$\log(p+1)$ e $\log(r+1)$], com o objetivo de comprimir a escala do gráfico. A unidade somada ao valor de p e r tem a função de evitar resultados negativos do logaritmo quando os parâmetros assumirem valores entre 0 e 1, restringindo os pontos ao primeiro quadrante do gráfico tridimensional. O agrupamento dos pontos pode ser realizado através de técnicas de clusterização ou por análise visual (UZUMERI; NEMBHARD, 1998).

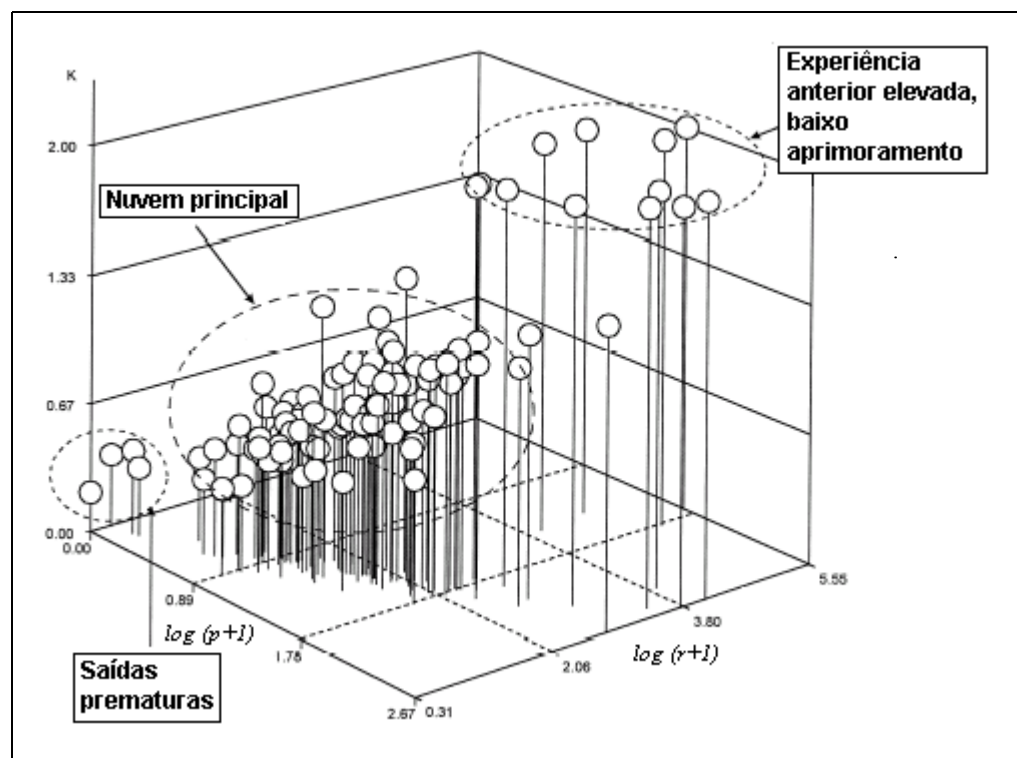


Figura 6: Gráfico tridimensional do aprendizado organizacional (adaptado de UZUMERI; NEMBHARD, 1998)

Nuvens de pontos próximas na Figura 6 correspondem a grupos de trabalhadores com características semelhantes de atuação. A identificação dos grupos com características semelhantes permite a alocação dos trabalhadores em tarefas apropriadas.

A Figura 7 apresenta as correlações existentes entre os três parâmetros, mostrando que trabalhadores que apresentam progresso lento e gradual (maior r) atingem um desempenho final mais elevado (maior k) e mantêm esse desempenho por mais tempo. Tais trabalhadores poderiam ser direcionados para tarefas com mais longa duração, visto que o aprendizado mais lento seria compensado por um desempenho final mais elevado ao longo da corrida de produção. Em contrapartida, aprendizes mais rápidos atingem menores patamares de desempenho final e apresentam um potencial de esquecimento maior. Para esses trabalhadores, as tarefas consideradas ideais estão ligadas a pequenos lotes de produção sujeitos a alterações frequentes, onde é necessário um aprendizado rápido. A análise dessas correlações permite a alocação adequada dos agrupamentos de trabalhadores formados na Figura 6 a tarefas específicas (UZUMERI; NEMBHARD, 1998; WICKENS; GORDON; LIU, 1998).

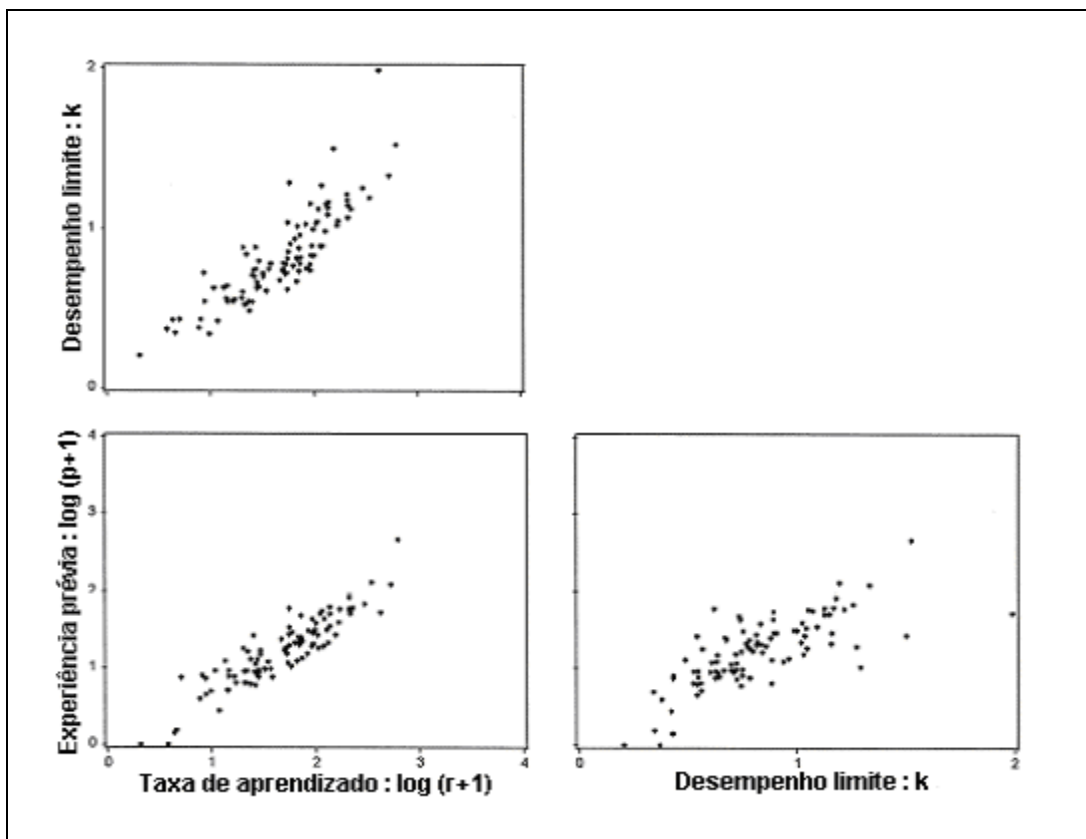


Figura 7: Correlações dos parâmetros k , p e r (Adaptado de UZUMERI; NEMBHARD, 1998)

Segundo Uzumeri e Nembhard (1998), o agrupamento de trabalhadores através da equação hiperbólica de 3 parâmetros apresenta vantagens sobre os modelos tradicionais que se propõem a esse fim. A visualização da organização como uma população de curvas permite priorizar os fatores mais importantes para sua caracterização (representados pelos parâmetros k , p e r), eliminando fatores de menor importância e de ocorrência esporádica. A análise dos parâmetros gerados pelas curvas permite identificar ocorrências externas que estejam influenciando o aprendizado da organização, bem como avaliar a velocidade de aprendizado frente a eventuais alterações de procedimento. A análise dos mapas permite ainda detectar diferenças de desempenho de aprendizado em diferentes tarefas, diferentes instantes de tempo ou entre trabalhadores com níveis distintos de treinamento, bem como entre trabalhadores recém-contratados e retreinados.

Buscando avaliar o potencial do modelo proposto em Uzumeri e Nembhard (1998), Nembhard e Uzumeri (2000a) realizaram comparações daquele com 10 outros modelos destinados à avaliação do desempenho de trabalhadores. Os mesmos dados modelados em Uzumeri e Nembhard (1998) foram utilizados, referindo-se a uma amostragem de 3874 trabalhadores submetidos a 30 operações distintas em diversos setores. Para efetuar a classificação dos modelos, foram adotados os seguintes critérios (sugeridos por UZUMERI; NEMBHARD, 2000a):

(i) eficiência - ajuste a vários comportamentos de dados de desempenho, possibilitando a descrição de aprendizado positivo e negativo, bem como a existência de aprendizado anterior. Para a medição da eficiência, foi utilizada a média do quadrado da distância entre os valores previstos pela curva e os observados ($\hat{\mu}_{MSE}$);

(ii) estabilidade - a curva deve apresentar a menor variabilidade possível perante os grupos de dados, sendo medida pela variância dos quadrados dos erros ($\hat{\sigma}_{MSE}$). Valores baixos de $\hat{\sigma}_{MSE}$ indicam que o modelo retrata com qualidade a maioria dos membros da população submetidos à modelagem; e

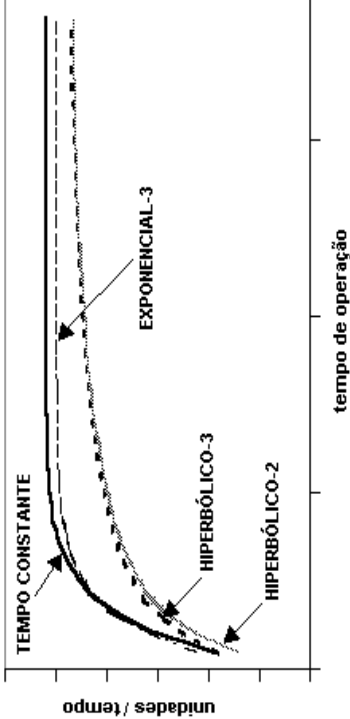
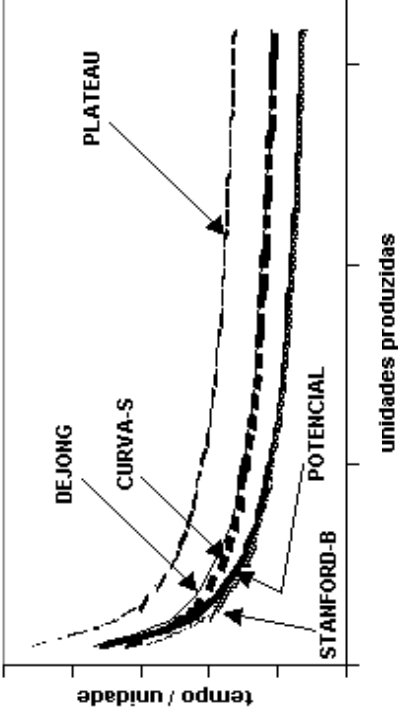
(iii) parcimônia - curvas com poucos parâmetros são preferíveis, especialmente quando se dispõe de poucos dados de desempenho a serem modelados. Um número reduzido de parâmetros possibilita a construção de gráficos, interpretação mais precisa dos parâmetros e menores valores de $\hat{\mu}_{MSE}$.

A Tabela 1 apresenta o desempenho de parte dos modelos de curva (7 de uma totalidade de 11) testados no experimento de Uzumeri e Nembhard (2000a). O % de erro (menor é melhor) representa o desvio dos demais modelos em relação ao modelo hiperbólico de 3 parâmetros, o qual foi utilizado como referência por apresentar os menores valores absolutos de $\hat{\sigma}_{MSE}$ e $\hat{\mu}_{MSE}$.

Tabela 1: Desempenho dos modelos de curvas de aprendizado (Adaptado de NEMBARD; UZUMERI, 2000a)

MODELO	FORMA	FALTA DE EFICIÊNCIA μ_{MSE} (% de erro)	FALTA DE ESTABILIDADE σ_{MSE} (% de erro)	Nº PARÂMETROS	COND. P/APREND. NEGATIVO
HIPERBÓLICO-3	$y=k[(x+p)/(x+p+r)]$	0,00577 (0%)	0,01183 (0%)	3	$r < 0$
EXPONENCIAL-3	$y=k(1-e^{-(x+p)^r})$	0,00598 (+3,6%)	0,01382 (+16,8%)	3	-
DEJONG	$y=C[M+(1-M)x^{-b}]$	0,00665 (+15,3%)	0,01331 (+12,5%)	3	$b > 0$
STANFORD-B	$y=C(x+B)^{-b}$	0,00671 (+16,3%)	0,01340 (+13,3%)	3	-
POTENCIAL	$y=Cx^{-b}$	0,00711 (+23,2%)	0,01434 (+21,2%)	2	-
CURVA-S	$y=C[M+(1-M)(x+B)^{-b}]$	0,00736 (+27,6%)	0,01506 (+27,3%)	4	$b < 0, 0 < m < 1$
HIPERBÓLICO-2	$y=k[x/(x+r)]$	0,00873 (+51,3%)	0,01410 (+19,2%)	2	$-1 < r < 0$

A equação hiperbólica de 3 parâmetros [equação (16)] foi escolhida como a que melhor retrata o aprendizado de uma população de trabalhadores, visto que apresentou os melhores resultados frente aos critérios propostos por Uzumeri e Nembhard (2000a). Em comparação com o tradicional modelo potencial, o modelo hiperbólico mostrou-se muito mais eficiente e estável, apesar de apresentar um parâmetro a mais. O Quadro 2 apresenta um resumo das principais características das curvas de aprendizado univariadas acima descritas. Nesse quadro são apontados os modelos de curvas mais aptos a serem utilizados em situações específicas de modelagem, como em cenários onde se verifica esquecimento e onde é demandada a participação de máquinas. O Quadro 2 também classifica os modelos de curvas de acordo com a unidade de medida das variáveis y e x (variável de resposta e variável independente, respectivamente).

MODELO	FORMA	Nº PARÂMETROS	MODELAGEM DE ESQUECIMENTO	EXPERIÊNCIA PRÉVIA	PARTICIPAÇÃO DE MÁQUINAS NA OPERAÇÃO	PERFIS DAS FAMÍLIAS DE CURVAS
HIPERBÓLICO-2	$y = k [x / (x + r)]$	2	✓			
HIPERBÓLICO-3	$y = k [(x + p) / (x + p + r)]$	3	✓	✓		
EXPONENCIAL-3	$y = k (1 - e^{-(x+p)/r})$	3		✓		
TEMPO CONSTANTE	$y = y_c + y_f (1 - e^{-x/t})$	3		✓		
POTENCIAL	$y = Cx^{-b}$	2				
PLATEAU	$y = B + Cx^{-b}$	3				
STANFORD-B	$y = C(x + B)^{-b}$	3		✓		
DEJONG	$y = C [M + (1 - M)x^{-b}]$	3	✓		✓	
CURVA-S	$y = C [M + (1 - M)(x + B)^{-b}]$	4	✓		✓	

Quadro 2: Resumo das principais características dos modelos de curvas de aprendizagem univariados

2.3.5 Modelos de Esquecimento

A ocorrência de paradas freqüentes de produção e modificações nas especificações dos produtos originou uma série de estudos que buscaram modelar e quantificar os seus efeitos, principalmente no que se refere ao esquecimento dos trabalhadores. O esquecimento se traduz na forma de diminuição no desempenho do trabalhador quando submetido a uma tarefa após um período de inatividade. Observa-se também a fabricação de produtos de qualidade inferior àqueles obtidos durante a produção contínua, principalmente nos primeiros ciclos. Bailey e McIntyre (2003) colocam que a capacidade de prever o nível de desempenho dos trabalhadores, quando da retomada das tarefas, permite uma melhor aplicação de recursos e planejamentos de produção mais precisos.

Globerson, Levin e Shtub (1989) realizaram um estudo envolvendo trabalhadores em um laboratório de microcomputação, os quais eram responsáveis pela realização de uma tarefa e por sua repetição depois de determinado intervalo de tempo (variando de 1 a 82 dias). Sete modelos de equações foram ajustados para previsão do desempenho dos trabalhadores quando da retomada das atividades, sendo que o modelo potencial apresentado na equação (17) apresentou melhor aderência aos dados. A retomada de desempenho modelada pela equação (17) é representada na Figura 8.

$$a_2 = C_0 F^{C_1} D^{C_2} \quad (17)$$

onde:

a_2 - desempenho (tempo/unidade) do trabalhador na unidade n (primeira unidade do segundo ciclo);

F - desempenho que seria verificado para a unidade n na ausência de interrupção, obtida através da curva de aprendizado utilizada para o monitoramento do primeiro ciclo;

D - tempo de parada;

C_0 , C_1 e C_2 - coeficientes do modelo.

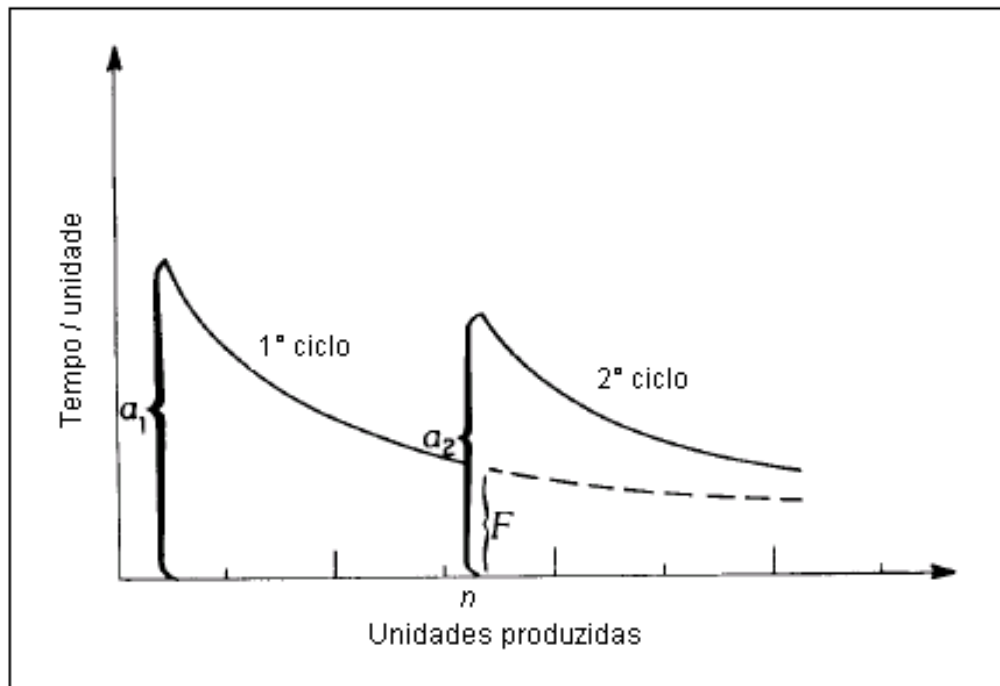


Figura 8: Efeito do esquecimento no desempenho (Adaptado de GLOBERSON *et al.* (1989))

A verificação de que uma curva potencial semelhante à proposta por Wright é capaz de descrever o processo de esquecimento levou Globerson, Levin e Shtub (1989) a sugerir que os processos de aprendizado e esquecimento ocorrem de maneira bastante similar. Os expoentes da equação (17) obtidos nesse experimento ($C_1 = 0,9$ e $C_2 = 0,09$) mostraram que o desempenho do trabalhador no segundo ciclo sofre maior influência do seu desempenho anterior à parada do que do tempo de parada.

Jaber e Bonney (1996) também desenvolveram um modelo capaz de descrever o fenômeno de esquecimento por uma curva potencial semelhante à proposta por Wright. Nesse modelo foi incluído um parâmetro denominado “declividade de esquecimento”, o qual é dependente da declividade de aprendizado, experiência anterior e tempo mínimo de parada até que se verifique esquecimento total. Deduções matemáticas partindo do modelo potencial possibilitaram obter variáveis capazes de prever o comportamento dos trabalhadores submetidos a paradas de produção. Tais variáveis quantificam o conhecimento remanescente e permitem determinar o tempo necessário para fabricação da primeira unidade do segundo ciclo, quando a produção é retomada. O modelo também possibilita estimar o tempo a partir do qual se verifica esquecimento total por parte do trabalhador em relação a uma tarefa. Os resultados obtidos por Jaber e Bonney (1996) foram comparados aos valores oriundos do

experimento proposto por Globerson, Levin e Shtub (1989), verificando-se diferenças desprezíveis entre as previsões dos dois modelos.

Bailey e McIntyre (2003) realizaram estudo semelhante utilizando modelos de previsão para a determinação dos parâmetros de uma curva de aprendizado potencial – definida pelos autores como “curva de reaprendizado” - capaz de descrever o processo de readaptação do trabalhador a uma tarefa. Para sua utilização, são necessários os parâmetros da curva de aprendizado original e o tempo que o trabalhador esteve afastado da tarefa. Os autores compararam os resultados das previsões dessa curva com os valores gerados por outra curva construída a partir dos dados coletados no reingresso do trabalhador à tarefa, sendo o desvio percentual entre as previsões muito baixo.

Salameh, Abdul-Malak e Jaber (1993) desenvolveram um modelo modificado de previsão de produção que avalia o efeito do aprendizado dos trabalhadores na determinação do lote ótimo de produção. Jaber e Bonney (1996), estendendo o estudo de Salameh, Abdul-Malak e Jaber (1993), incorporaram o esquecimento ao modelo proposto com o propósito de analisar seu efeito sobre o tamanho do lote ótimo de produção e custo de estoque. Segundo Jaber e Bonney (1996), o lote ótimo de produção sofre redução contínua em seu tamanho quando se verifica transmissão integral de conhecimento, ou seja, situações onde exista produção seqüencial de lotes sem paradas longas. Essa redução é decorrente do aprimoramento do desempenho dos trabalhadores e é verificada até que se atinja patamar de aprendizado máximo na tarefa em questão. A transmissão de conhecimento não é integral quando ocorrem paradas de produção e gera-se esquecimento, resultando em lotes de tamanho constante. O esquecimento acarreta redução na taxa média de produção e ciclos mais longos, gerando maiores gastos com estoque.

A modificação de parâmetros de determinado processo ou produto durante sua vida útil, a exemplo das paradas de produção, acarreta consideráveis diminuições no desempenho dos trabalhadores (YELLE, 1979). Tais modificações geralmente provêm de exigências de consumidores ou de adequação do produto a novas normas ou destinos, o que representa custos com reprojeto, retrabalho e aprendizado por parte dos trabalhadores envolvidos (EDEN; WILLIAMS; ACKERMANN, 1998). Wright (1936) verificou o efeito de modificações no processo de montagem de aviões durante o desenvolvimento dos princípios das curvas de aprendizado, sugerindo erroneamente que essas modificações não seriam de grande impacto e que as produções futuras da indústria aeronáutica seguiriam uma padronização, o que não aconteceu na realidade.

Avaliando os efeitos das modificações sobre o aprendizado do trabalhador, Eden, Willians e Ackermann. (1998) verificaram que cada pequena alteração de procedimento demandava mais tempo para conclusão da tarefa. Esse aumento de tempo se justificava na necessidade de adaptação do trabalhador à nova forma de execução da tarefa. Eden, Willians e Ackermann (1998) propuseram um modelo de curva de aprendizado capaz de incorporar o acréscimo de tempo demandado por cada alteração de procedimento ao tempo total de processo. Esse modelo se constitui em um somatório e está baseado no conceito de tempo padrão de produção (T_s), o qual pode ser definido como o tempo ideal para realização de uma tarefa, considerando-se estado estacionário de produção e afinidade do trabalhador com o ferramental envolvido na execução da tarefa. À medida que modificações são realizadas no processo, o tempo padrão é corrigido com base em dados experimentais e incluído na equação (18).

$$\sum_1^N T_i = NT_s + KT_s \sum_1^N 2^{b \log 2(i)} + KT_{s1} \sum_{n_1}^N 2^{b \log 2(i)} \quad (18)$$

onde:

N - número total de unidades fabricadas;

T_i - tempo total para execução de N unidades;

T_s - tempo padrão inicial para execução da atividade;

T_{s1} - tempo padrão de execução depois de determinada alteração no processo (tempo inicial de execução acrescido do tempo decorrente da alteração);

b - coeficiente de aprendizado;

i - número de unidades fabricadas;

K - coeficiente para um determinado processo.

Aconselha-se a utilização da equação (18) para determinar o tempo total demandado em corridas mais longas de produção. Em casos de mudanças mais acentuadas nos parâmetros do produto ou processo, deve ser acrescentado à equação um termo referente ao retrabalho das

unidades fabricadas até o momento da alteração (EDEN; WILLIAMS; ACKERMANN, 1998).

2.3.6 Modelos Multivariados

Modificações e extensões das tradicionais curvas de aprendizado são necessárias para uma melhor caracterização do processo de aprendizado quando se deseja analisar a influência de fatores qualitativos e quantitativos (BADIRU, 1992). Os modelos multivariados fazem uso de duas ou mais variáveis independentes, assumindo a forma genérica apresentada na equação (19).

$$C_x = K \prod_{i=1}^n c_i x_i^{b_i} \quad (19)$$

onde:

C_x – desempenho (custo) médio acumulativo por unidade observado em uma dada combinação de valores das variáveis independentes;

K – desempenho (custo) da primeira unidade;

x_i – valor da variável independente i ;

n – número de variáveis independentes utilizadas no modelo;

c_i – coeficiente da variável independente i ;

b_i – declividade de aprendizado para a variável independente i .

Quando o modelo apresentado na equação (19) utilizar duas variáveis independentes para descrição do processo de aprendizado, é possível analisar a influência das variáveis x_1 e x_2 através de gráficos de superfície, como o apresentado na Figura 9.

Badiru (1992) apresenta modelos de curvas de aprendizado multivariadas, bem como seus setores de aplicação. Alerta, entretanto, que a adição de variáveis independentes de menor relevância ao modelo gera problemas em procedimentos de regressão. A eventual multicolinearidade (correlação) entre variáveis supostamente independentes é outra limitação dos modelos multivariados.




Figura 9: Gráfico genérico de uma curva de aprendizado bivariada (Adaptado de BADIRU, 1992)

Estudos realizados por Badiru (1992) compararam o poder de predição dos modelos univariados e multivariados. A curva multivariada contava com duas variáveis independentes: unidades produzidas (x_1) e tempo de treinamento (x_2), responsáveis pelo monitoramento dos custos (C_x). O modelo univariado consistia na equação de Wright, onde os custos eram dependentes do número de unidades produzidas. O coeficiente de determinação gerado pelos modelos foi bastante similar. Badiru (1992) concluiu que o modelo multivariado fornece informações importantes sobre a interação das variáveis independentes. Assim, a utilização desse modelo é aconselhada quando se dispõe de informações sobre as variáveis independentes. Caso contrário, o modelo univariado apresenta-se como melhor alternativa, dada a sua simplicidade.

2.4 ANÁLISE DE CLUSTERS

Análise de *clusters* é uma técnica multivariada que permite agrupar objetos (produtos, modelos e outras entidades) segundo suas características. Um objeto pertencente a determinado grupo é considerado similar aos demais objetos pertencentes àquele grupo de acordo com o critério utilizado para o agrupamento. Os *clusters* formados apresentam homogeneidade entre os objetos que compõem um grupo e diferenças acentuadas entre os objetos pertencentes a diferentes grupos (JOHNSON; WICHERN, 1992; HAIR *et al.*, 1995).

A análise de *clusters* tem sido utilizada para reduzir o número de dados a serem analisados em diversas situações, identificando cada grupo pelo seu perfil característico. O agrupamento dos objetos permite analisar uma quantidade reduzida de dados, sem haver, no entanto, perda significativa de informações (HAIR *et al.*, 1995).

Algumas aplicações da análise de *clusters* buscam incluir um ou mais objetos em grupos já existentes, de maneira a garantir a maior similaridade entre o(s) objeto(s) inserido(s) e o grupo de destino. A análise também é utilizada para formulação de hipóteses e classificações através dos *clusters* formados, sendo exemplos de aplicação as áreas de botânica e zoologia (SEBER, 1984).

O processo de clusterização é efetuado através de procedimentos de aglomeração de objetos ou indivíduos a partir de variáveis de clusterização.

2.4.1 Variáveis de Clusterização

As características dos objetos a serem comparados e agrupados são descritas através de variáveis de clusterização. Essas variáveis são usadas para o cálculo da similaridade entre os objetos e podem ser representadas por valores absolutos, por valores derivados de uma escala pré-definida ou por valores binários, indicando a presença ou não de determinada característica (HAIR *et al.*, 1995).

As variáveis de clusterização devem ser selecionadas de maneira a caracterizar de forma segura os objetos, abordando características que estejam de acordo com o propósito do agrupamento. A clusterização efetuada com variáveis mal dimensionadas ou que não sejam relevantes para a caracterização dos objetos leva a resultados distorcidos, visto que os

métodos de clusterização utilizados não distinguem a importância ou representatividade da variável na análise em questão (HAIR *et al.*, 1995).

A escolha adequada das variáveis de clusterização minimiza a ocorrência de valores extremos das variáveis (em objetos que são muito diferentes dos demais), conhecidos como *outliers*. Segundo Hair *et al.* (1995), os pontos extremos devem ser avaliados quanto à sua influência na estruturação dos grupos e, se necessário, devem ser eliminados para não gerarem distorções nas conclusões.

2.4.2 Medições de Similaridade

A medição de similaridade entre os objetos é fundamental para a formação de *clusters*. A medida é obtida através de procedimentos matemáticos sobre as variáveis de clusterização para todos os pares de objetos que estão sendo avaliados, possibilitando a comparação entre quaisquer objetos (JOHNSON; WICHERN, 1992).

Existem três métodos principais para a medição da similaridade entre objetos: (i) medições de correlação, (ii) medições de distância e (iii) medições associadas. Os dois primeiros métodos utilizam dados métricos para efetuar a medição, enquanto que o último opera com dados não-métricos.

As **medições de correlação** permitem identificar similaridades entre os objetos através da análise do coeficiente de correlação entre as variáveis de clusterização que caracterizam esses objetos. Essa forma de medição está baseada no padrão dos valores, ou seja, avalia-se se as características dos objetos apresentam ou não correlação entre si. No caso de existência de correlação, avalia-se se essa é positiva ou negativa. As medições de correlação não levam em consideração a magnitude dos valores das variáveis que caracterizam os objetos.

Medições de distância são usadas com maior frequência do que as medições de correlação para avaliar a similaridade entre objetos. A magnitude da distância entre os objetos permite extrair conclusões precisas quanto à proximidade (similaridade) entre os mesmos.

Dentre as várias formas de obtenção da distância entre objetos, destaca-se a Distância Euclidiana, apresentada na equação (20). Essa medida de similaridade avalia a distância entre as variáveis de clusterização que descrevem dois objetos, permitindo comparar a proximidade de um objeto com todos os demais aos pares. Os objetos que apresentam menores valores de

distância Euclidiana entre si possuem maior similaridade entre suas características e são candidatos a integrarem um mesmo grupo (JOBSON, 1992). A distância Euclidiana também pode ser expressa ao quadrado, eliminando o efeito de sinal nos procedimentos numéricos.

$$d_{rs}^2 = \sum_{j=1}^p (x_{rj} - x_{sj})^2 \quad (20)$$

onde:

d_{rs}^2 - quadrado da distância Euclidiana;

x_r/x_s - variáveis de clusterização avaliadas quanto aos objetos r e s ;

p - número de variáveis de clusterização.

Medições associadas são utilizadas para a avaliação de similaridade entre objetos cujas características são medidas exclusivamente em termos não-métricos. Estes casos são representados por situações onde as variáveis de clusterização limitam-se a descrever a presença ou não de determinada característica, assumindo valores binários (0 e 1) (HAIR *et al.*, 1995).

2.4.3 Formação de *Clusters*

A formação dos *clusters* é efetuada através da aplicação de um algoritmo de clusterização apropriado, utilizando as medições de similaridade entre os objetos. Os algoritmos utilizados para formação de *clusters* podem ser classificados em duas categorias principais: métodos hierárquicos e métodos não-hierárquicos.

Os **métodos hierárquicos** consistem no agrupamento sucessivo dos objetos através da comparação das suas medições de similaridade. Inicialmente, dois objetos são unidos para formarem um primeiro *cluster*, segundo um procedimento de aglomeração definido. Nas etapas subseqüentes, os demais objetos (ou *clusters*) são unidos segundo o mesmo procedimento, reduzindo em um o número de *clusters* a cada passo. As agregações são

realizadas até obter-se o número de grupos desejado, o qual será identificado subjetivamente pelo analista. Um objeto incluído em um *cluster* não pode ser retirado e direcionado a outro. O método é monitorado através de um dendograma, que consiste na representação gráfica do procedimento de aglomeração, relacionando os *clusters* formados e os objetos contidos em cada grupo (HAIR *et al.*, 1995).

Os procedimentos de aglomeração dentro do método hierárquico podem ser realizados de várias maneiras, podendo gerar diversas soluções válidas. Os procedimentos de aglomeração se diferenciam pela forma com que avaliam as distâncias de similaridade. Os procedimentos mais utilizados são: (i) união simples (*single linkage*) – junta os dois objetos com a menor distância entre si, gerando o primeiro *cluster*. As demais agregações seguem o mesmo princípio; (ii) união completa (*complete linkage*) – avalia a distância máxima que pode existir entre objetos de um *cluster*. Os objetos que excederem essa distância devem ser agrupados em outro *cluster*; (iii) união média (*average linkage*) – avalia a distância média dos objetos que compõem um *cluster* em relação aos demais *clusters*; (iv) método de Ward (*Ward's method*) – busca minimizar a soma do quadrado da distância dos objetos que compõem cada *cluster*; (v) método do centróide (*centroid method*) – a distância entre dois *clusters* é avaliada pela distância entre os centróides dos *clusters*. A menor distância de um objeto aos centróides dos grupos já formados aponta em que *cluster* o objeto deve ser inserido (JOHNSON; WICHERN, 1992; HAIR *et al.*, 1995).

Os **métodos não hierárquicos** de clusterização não operam em uma seqüência de agrupamentos como os métodos hierárquicos, mas partem de um número pré-definido de *clusters* desejados. Para tanto, são selecionados k “*clusters* de origem”, os quais abrangem os objetos que se encontram dentro de um raio de distância especificada. À medida que os *clusters* são formados, as distâncias dos objetos aos *clusters* são reavaliadas, fazendo com que objetos pertencentes a um *cluster* possam migrar para outro onde encontrem maior similaridade com os demais objetos. Esse procedimento é denominado *k-means*, sendo que a medição de similaridade é baseada na distância Euclidiana (GNANADESIKAN, 1997).

2.4.4 Escolha do Método de Clusterização

Os métodos hierárquicos são aconselhados para situações onde não se conhece o número de *clusters* a serem formados. A aglomeração gradual permite visualizar o processo de inserção dos objetos aos *clusters* e analisar os resultados que são gerados. Entretanto, o

método pode conduzir a resultados equivocados quando inicia com uma combinação de objetos indesejada. Os métodos hierárquicos são suscetíveis à presença de pontos extremos (*outliers*) (HAIR *et al.*, 1995).

Os métodos não-hierárquicos operam com um número especificado de *clusters* a serem formados e não são afetados por pontos extremos das variáveis. A escolha dos “*clusters* de origem” no método não-hierárquico é o fator chave para a obtenção de resultados precisos e rapidez na convergência (GNANADESIKAN, 1997). A seleção aleatória dos “*clusters* de origem” conduz a resultados inferiores quando comparados com os grupos oriundos de pontos de origem especificados.

Uma seqüência aconselhada para obtenção de bons resultados no processo de formação de *clusters* é a aplicação de métodos hierárquicos para estimação do número de grupos a serem formados e para eliminação ou tratamento de valores extremos das variáveis de clusterização. Os métodos não-hierárquicos podem ser utilizados na seqüência, fazendo uso dos “*clusters* de origem” apontados pelos métodos hierárquicos (HAIR *et al.*, 1995).

2.4.5 Interpretação e Avaliação dos Resultados

A validação dos *clusters* formados depende da sua capacidade de representar diferentes perfis de uma população, sem perda significativa de informações. Hair *et al.* (1995) propõem uma maneira de avaliar a consistência dos resultados: (i) separar aleatoriamente os objetos que serão clusterizados em dois subgrupos, (ii) proceder às técnicas de clusterização em cada subgrupo e (iii) comparar os resultados obtidos. A formação de grupos com características semelhantes em cada procedimento mostra que os *clusters* formados são consistentes.

Segundo Gnanadesikan (1997), um critério bastante simples para avaliação do resultado de um processo de clusterização é a análise das principais características dos objetos em um *cluster* frente aos objetos dos demais *clusters*, de maneira a justificar sua inclusão em um grupo separado. Gráficos relacionando o desvio da média de uma variável em determinado *cluster* frente à média geral daquela variável em todos os *clusters* também são úteis para avaliação dos resultados.

Os *clusters* formados podem apresentar diferentes soluções válidas em função da técnica de medição de similaridade utilizada para aglomeração. A comparação das soluções

provenientes de medições de similaridade distintas frente a padrões de resposta pré-estabelecidos para os objetos em análise é uma forma de ratificar os resultados (HAIR *et al.*, 1995).

2.5 REGRESSÃO LINEAR MÚLTIPLA

O objetivo da análise de regressão é estimar o valor de uma variável dependente a partir do conhecimento de uma ou mais variáveis independentes. A regressão linear múltipla estabelece uma relação entre a variável de resposta y e as k variáveis de regressão (x_1, x_2, \dots, x_k), sendo representada através da equação (21) (JOHNSON; WICHERN, 1992).

$$y_i = \beta_0 + \beta_1 x_{i1} + \beta_2 x_{i2} + \dots + \beta_k x_{ik} + \varepsilon_i \quad (21)$$

onde $\beta_0, \beta_1, \beta_2, \dots, \beta_k$ são definidos como coeficientes de regressão do modelo (determinados conforme seção 2.5.1). O parâmetro β_j representa a variação esperada na variável de resposta y devido à variação de uma unidade de x_j , quando as demais variáveis de regressão são mantidas inalteradas. O termo “linear” é justificado pelo fato da equação ser uma função linear dos coeficientes de regressão (MONTGOMERY; RUNGER, 1994).

A equação (21) possibilita uma boa estimativa de y para valores de x_1, x_2, \dots, x_k que estejam dentro do intervalo de dados que originou os coeficientes de regressão da equação. Esse modelo descreve um plano no espaço k -dimensional definido pelas x_k variáveis de regressão.

A construção de gráficos relacionando as variáveis de regressão ($x_i \times x_j$) permite verificar a existência de multicolinearidade entre as variáveis. A multicolinearidade indica que duas ou mais variáveis de regressão são dependentes entre si, o que dispensa a inclusão de ambas no modelo de regressão. Variáveis nesta situação podem gerar distúrbios na aplicação do método dos erros quadrados para determinação dos coeficientes de regressão e tornar o modelo pouco preciso (MONTGOMERY; PECK, 1992).

O parâmetro de erro ε_i representa o desvio entre os valores observados e os estimados para a i -ésima observação e não deve possuir informação sistemática para a determinação de y

que não tenha sido capturada pelas variáveis x_k . O parâmetro de erro é pressuposto como independente e normalmente distribuído (CHATTERJEE; PRICE, 1991).

Equações de estrutura mais complexa (polinômios e interações) podem ser analisadas por regressão linear múltipla através do ajuste da equação a uma forma linearizada, conforme exemplificado nas equações (22) e (23).

$$y_i = \beta_0 + \beta_1 x_1 + \beta_2 x_2 + \beta_{11} x_1^2 + \beta_{22} x_2^2 + \beta_{12} x_1 x_2 \quad (22)$$

Substituindo $x_3 = x_1^2$, $x_4 = x_2^2$ e $x_5 = x_1 x_2$, $\beta_3 = \beta_{11}$, $\beta_4 = \beta_{22}$ e $\beta_5 = \beta_{12}$, obtém-se a equação (23), que é a forma linearizada da equação (22).

$$y = \beta_0 + \beta_1 x_1 + \beta_2 x_2 + \beta_3 x_3 + \beta_4 x_4 + \beta_5 x_5 \quad (23)$$

A determinação dos coeficientes de regressão permite determinar a influência de cada variável de regressão sobre a variável de resposta y .

2.5.1 Determinação dos Coeficientes de Regressão

Os coeficientes de regressão do modelo ($\hat{\beta}$) podem ser estimados pelo método dos mínimos quadrados. Admitindo a existência de um número de observações n maior que k e definindo x_{ij} como a i -ésima observação da variável x_j , pode-se representar o modelo de regressão linear pela forma genérica apresentada na equação (24) (MONTGOMERY; RUNGER, 1994).

$$y_i = \beta_0 + \sum_{j=1}^k \beta_j x_{ij} + \varepsilon_i \quad i = 1, 2, \dots, n \quad (24)$$

A função erro é apresentada na equação (25).

$$L = \sum_{i=1}^n \varepsilon^2 = \sum_{i=1}^n \left(y_i - \beta_0 - \sum_{j=1}^k \beta_j x_{ij} \right)^2 \quad (25)$$

A função L é minimizada através da sua derivação com respeito aos coeficientes de regressão $\beta_0, \beta_1, \dots, \beta_k$, gerando os coeficientes de regressão estimados $(\hat{\beta}_0, \hat{\beta}_1, \dots, \hat{\beta}_k)$. Os coeficientes $\hat{\beta}$ são determinados através da solução do sistema de equações lineares gerado pela derivação, por meio de método apropriado.

Um sistema alternativo para a representação de n equações segue a notação matricial na equação (26), facilitando a identificação das variáveis e procedimentos matemáticos (JOBSON, 1991).

$$\mathbf{y} = \mathbf{X}\boldsymbol{\beta} + \boldsymbol{\varepsilon} \quad (26)$$

Na equação (26), \mathbf{y} é um vetor ($n \times 1$) de observações, \mathbf{X} é uma matriz ($n \times p$) contendo os níveis das variáveis de regressão (sendo as colunas desta matriz linearmente independentes), $\boldsymbol{\beta}$ é o vetor ($p \times 1$) dos coeficientes de regressão e $\boldsymbol{\varepsilon}$ é o vetor de erro, com dimensão ($n \times 1$). A dimensão p é constituída pelas k variáveis de regressão e por uma constante correspondente ao parâmetro β_0 (MONTGOMERY; RUNGER, 1994).

Manipulações matemáticas sobre os vetores \mathbf{y} , $\boldsymbol{\beta}$ e $\boldsymbol{\varepsilon}$ e sobre a matriz \mathbf{X} permitem estimar o vetor de coeficientes de regressão $\hat{\boldsymbol{\beta}}$ que minimiza o valor dos desvios quadrados na equação (25) (JOBSON, 1991). A equação (27) apresenta a forma matricial resultante das manipulações.

$$\hat{\boldsymbol{\beta}} = (\mathbf{X}'\mathbf{X})^{-1} \mathbf{X}'\mathbf{y} \quad (27)$$

O vetor $\hat{\boldsymbol{\beta}}$ representa os coeficientes de regressão estimados para o modelo apresentado na equação (21).

2.5.2 Adequação do Modelo de Regressão

Uma série de técnicas pode ser utilizada para avaliar a adequação de um modelo de regressão aos dados observados. Dentre essas, destacam-se: (i) análise de resíduos, (ii) coeficiente de determinação (R^2) e (iii) testes de hipótese.

2.5.2.1 Análise de Resíduo

A diferença entre o valor observado y_i e o correspondente valor estimado \hat{y}_i compõem o resíduo e_i . A utilização de diagramas dos resíduos possibilita avaliar a adequação do modelo de regressão estimado aos dados observados. O diagrama permite a detecção de pontos extremos, verificação de distribuição fora da normalidade e seleção equivocada de uma variável de regressão (DRAPER; SMITH, 1981; MONTGOMERY; PECK, 1992).

Os diagramas de resíduos apresentam formas alternativas de representação e análise. O resíduo e_i pode ser representado em um papel de probabilidade da distribuição Normal, exemplificado na Figura 10. A conformação dos dados em uma reta indica boa adequação dos dados ao modelo estimado (MONTGOMERY; PECK, 1992).

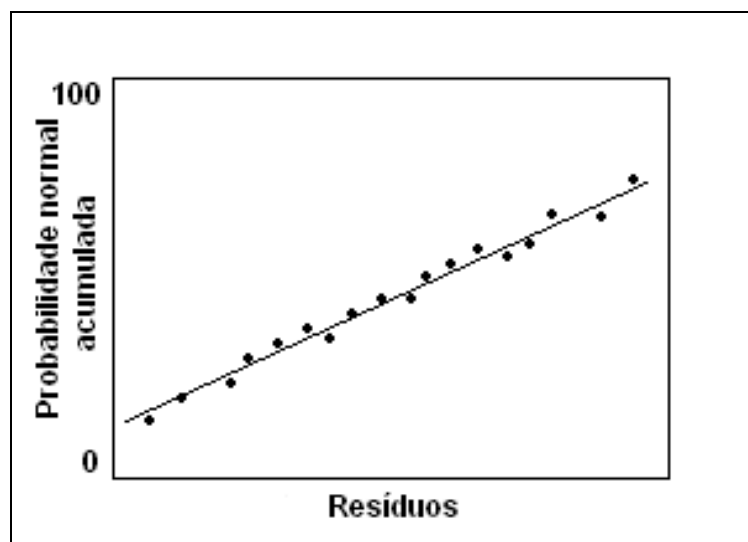


Figura 10: Gráfico de probabilidade normal dos resíduos (Adaptado de MONTGOMERY; PECK, 1992)

Os resíduos também podem ser comparados com cada variável de regressão (x_1, x_2, \dots, x_k) ou com os valores de y estimados (\hat{y}_i) através de gráficos. Os pontos gerados devem apresentar distribuição aleatória em torno do valor de resíduo igual a zero, conforme exemplificado na Figura 11. Essa forma de análise permite verificar tendências do modelo estimado com a variação das variáveis de regressão (MONTGOMERY; PECK, 1992).




Figura 11: Distribuição aleatória do resíduo (Adaptado de MONTGOMERY; RUNGER, 1994)

2.5.2.2 Coeficiente de Determinação (R^2)

O coeficiente de determinação múltipla (R^2) representa a proporção da variabilidade total de y explicada pelas variáveis de regressão x , sendo dado na equação (28). Um elevado valor de R^2 , entretanto, não significa necessariamente uma boa adequação do modelo aos dados observados, visto que a inclusão de variáveis pouco significativas no modelo eleva o valor do coeficiente (JOBSON, 1991; MONTGOMERY e RUNGER, 1994).

$$R^2 = \frac{SS_R}{S_{yy}} = 1 - \frac{SS_E}{S_{yy}} \quad (28)$$

onde:

R^2 - coeficiente de determinação ($0 \leq R^2 \leq 1$);

SS_R - soma dos quadrados da diferença entre a média da variável dependente e os valores estimados para todas observações;

SS_E - soma dos quadrados dos resíduos para todas observações;

S_{yy} - soma dos quadrados totais de y .

2.5.2.3 Testes de Hipóteses

A realização de testes de hipóteses sobre os parâmetros estimados permite avaliar a adequação do modelo aos dados observados. Os testes verificam a existência de relação linear entre a variável de resposta y e as variáveis de regressão x_k . A formulação de testes de hipóteses exige ε_i 's normal e independentemente distribuídos, com média igual a zero e variância σ^2 (MONTGOMERY; RUNGER, 1994).

CAPÍTULO 3

3 MÉTODO PROPOSTO

Neste capítulo sugere-se uma aplicação distinta da proposta de Uzumeri e Nembhard (1998), apresentada na seção 2.3.4, a qual originalmente se destina à descrição quantitativa do aprendizado de uma população de trabalhadores. O método proposto visa avaliar a adequação de equipes de trabalhadores às operações demandadas por diferentes produtos, com o propósito de direcioná-los às equipes mais habilitadas à sua execução. A alocação é baseada na análise dos parâmetros gerados pelas curvas de aprendizado.

O principal objetivo do direcionamento de produtos a equipes de trabalhadores mais habilitadas é reduzir as perdas decorrentes das trocas de modelos de produtos, situação essa particularmente comum no contexto de produção com flexibilidade de catálogo. As perdas se refletem nos baixos índices de desempenho e qualidade verificados nos primeiros ciclos de produção de um novo produto. A alocação adequada de trabalhadores a operações específicas permite melhores resultados de adaptação ao novo procedimento e menores índices de perdas por falta de destreza (UZUMERI; NEMBHARD, 1998).

O método proposto pode ser aplicado em processos de naturezas distintas, sendo relevantes as características das operações envolvidas. Procedimentos repetitivos exclusivamente manuais ou com pequena participação de maquinário constituem cenários ideais para a aplicação de curvas de aprendizado. Tais operações são exemplificadas por tarefas de montagem em geral, nas quais exigem-se destreza e rapidez dos trabalhadores na assimilação de novos procedimentos.

A aplicabilidade de curvas de aprendizado, com o propósito de direcionar modelos de produtos a equipes de trabalhadores, está baseada nas seguintes condições principais (definidas pelo autor através da análise das características de processos de montagem que apresentam alteração freqüente nos produtos fabricados):

- Alternância freqüente dos modelos de produtos em fabricação destinados às equipes analisadas;
- Manutenção dos integrantes das equipes de trabalhadores analisadas;
- Conhecimento prévio básico dos procedimentos de execução dos diferentes modelos de produtos por parte das equipes.

A alternância freqüente dos modelos de produtos em fabricação permite utilizar a curva de aprendizado para descrever o aprimoramento de desempenho apresentado pelos trabalhadores de uma equipe a cada troca de modelo. Paradas na produção ou modificações nas características de um produto demandam a readequação (aprendizado) do trabalhador à operação, gerando situações passíveis de modelagem pela curva. A atuação do trabalhador no mesmo produto durante longos períodos de tempo não justifica a utilização de curvas, visto que o aprendizado na operação pode ser considerado completo e as variações de desempenho são decorrentes de causas comuns do processo.

Ao monitorarem-se equipes de trabalhadores através de curvas de aprendizado, é fundamental que a equipe analisada apresente baixo percentual de rotatividade externa de seus integrantes, principalmente no período de coleta dos dados. A inclusão ou modificação de um número significativo de trabalhadores pode alterar o desempenho da equipe, demandando nova análise através das curvas.

A análise do desempenho de diferentes equipes na execução de modelos distintos de produtos subentende que as equipes detêm conhecimento prévio suficiente para realizar as operações demandadas para cada produto. Entende-se como conhecimento do trabalhador o fato deste já ter realizado operações similares à que está sendo solicitada ou o fato de ter recebido treinamento para execução da mesma. Equipes que não atenderem a essa condição também podem ser testadas, porém seu aprimoramento provavelmente será menor que o de outras equipes que já contam com experiência prévia.

O método proposto para o direcionamento de produtos às equipes de trabalhadores mais habilitadas é constituído pelas etapas descritas na seqüência. Estas etapas são apresentadas na Figura 12, que traz o fluxograma do método proposto:

1. Identificação dos modelos a serem considerados na análise e agrupamento dos mesmos por similaridade de características (formação de famílias de produtos). As características podem ser referentes à complexidade dos procedimentos de montagem e formas do produto, entre outras.
2. Identificação da amostra de trabalhadores (ou equipes de trabalhadores) a ser usada na coleta de dados.
3. Alocação das famílias de produtos formadas às equipes selecionadas para análise, gerando “cruzamentos” (equipes *versus* famílias de produtos).
4. Modelagem dos dados de desempenho obtidos nos cruzamentos através de modelos de curvas de aprendizado apresentados na literatura.
5. Análise dos parâmetros gerados pela curva de aprendizado selecionada, de acordo com a duração da corrida de produção. Esta etapa desdobra-se nas seguintes análises:
 - a. Análise de regressão sobre o parâmetro de taxa de aprendizado (corridas de curta duração);
 - b. Integração das curvas de aprendizado (corridas de durações distintas).
6. Alocação das famílias de produtos às equipes de trabalhadores mais aptas à execução das operações daquela família.

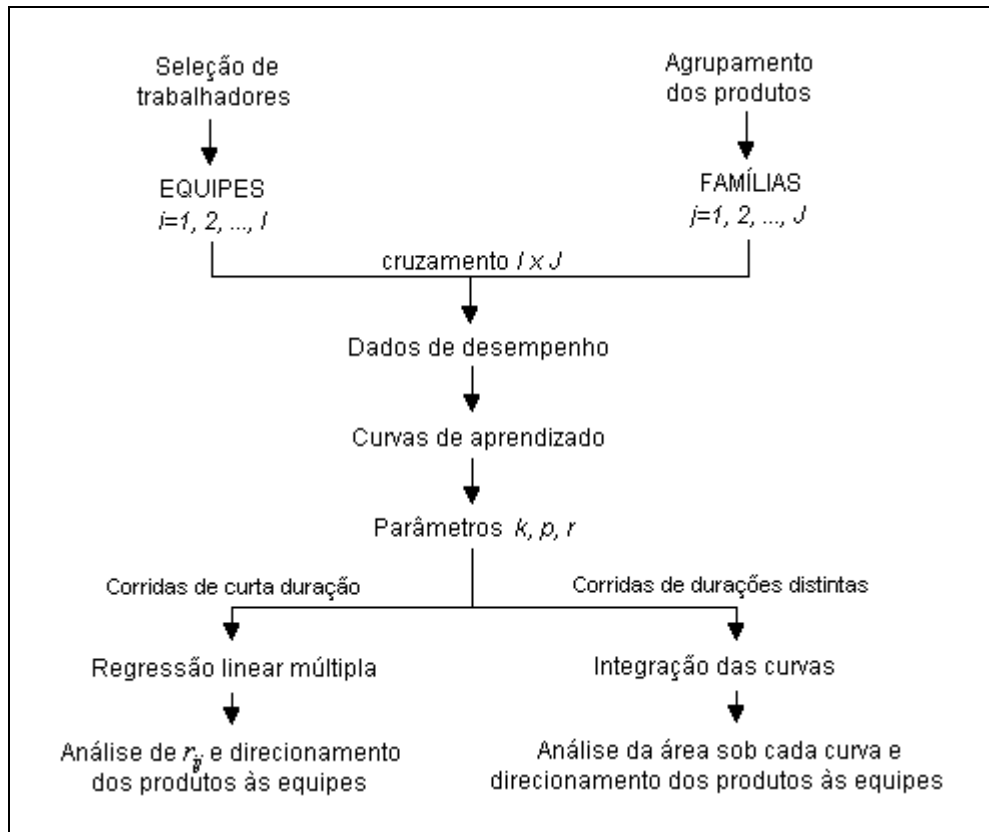


Figura 12: Fluxograma do método proposto

As etapas da metodologia proposta são detalhadas na seqüência.

3.1 IDENTIFICAÇÃO E AGRUPAMENTO DOS PRODUTOS COM CARACTERÍSTICAS SIMILARES

Essa etapa compreende a seleção dos produtos a serem direcionados às equipes de trabalhadores para processamento e coleta de dados de desempenho. Devem ser priorizados os produtos considerados mais representativos e rentáveis, de maneira a justificar a sua modelagem pelas curvas. Quando se dispõe de um grande número de produtos, procede-se ao agrupamento dos mesmos segundo suas características similares, gerando famílias de produtos.

O agrupamento pode ser realizado através de técnicas de clusterização. A geração de famílias de produtos com características semelhantes facilita o procedimento de modelagem, visto que a quantidade de dados é reduzida sem haver perda significativa de informação. As

conclusões obtidas para um produto pertencente a uma família podem ser estendidas para os demais integrantes daquela família (HAIR *et al.*, 1995).

As características selecionadas para a formação das famílias de produtos são definidas como variáveis de clusterização e devem ser relevantes para a formação de famílias representativas. Essas características estão relacionadas com particularidades físicas do produto, complexidade das operações envolvidas em sua fabricação e outras propriedades que permitam efetuar um agrupamento dos modelos.

As variáveis de clusterização podem ser quantitativas ou qualitativas, conforme apresentado na seção 2.4.1. As características a serem avaliadas podem ser selecionadas através da análise de bancos de dados, onde constem informações dos produtos ou por consultas a profissionais envolvidos em sua fabricação. A descrição de uma ou mais características, quando feita através de escalas numéricas, deve ser realizada pelo mesmo especialista para todos os produtos analisados, a fim de que exista uniformidade na avaliação das variáveis e precisão no agrupamento dos produtos. A Figura 13 apresenta um arranjo das características selecionadas para a formação das famílias de produtos.

		Produtos			
		<i>Produto 1</i>	<i>Produto 2</i>	<i>Produto n</i>
Características	<i>Caract. 1</i>				
	<i>Caract. 2</i>				
	⋮				
	<i>Caract. n</i>				

Figura 13: Arranjo das características dos produtos

O agrupamento pode ser realizado através de *software* estatístico apropriado para a formação de *clusters*. As famílias de produtos formadas são identificadas pelo índice j , tal que $j = 1, \dots, J$.

O número de famílias a ser gerado é dependente da quantidade e das características dos produtos analisados. A formação de um número elevado de famílias gera maior precisão

quanto às conclusões para os produtos pertencentes a cada família, porém exige maiores esforços para coleta de dados. A formação de um número reduzido de famílias, entretanto, pode resultar em agrupamentos de modelos pouco homogêneos, prejudicando futuras inferências, a partir das curvas de aprendizado, sobre a família.

3.2 IDENTIFICAÇÃO DA AMOSTRA DE TRABALHADORES A SER USADA NA COLETA DE DADOS

Objetiva-se selecionar amostras de trabalhadores (ou equipes de trabalhadores) a serem utilizados na coleta de dados de desempenho. Uma equipe pode ser composta por trabalhadores atuando na mesma operação ou executando operações distintas, como acontece em linhas de produção.

O monitoramento de equipes com o propósito de alocação de produtos demanda que as equipes estejam previamente formadas e aptas à execução das operações demandadas pelos produtos analisados. As equipes não devem apresentar elevado percentual de rotatividade externa, ou seja, as migrações de integrantes de uma equipe para outra devem ser evitadas, sob pena de modificarem o perfil de desempenho da equipe durante a análise.

A seleção de equipes de trabalhadores é feita através de consultas a supervisores de produção, realização de corridas de produção experimentais ou através da análise de bancos de dados de desempenho. Avalia-se o conhecimento teórico dos trabalhadores, destreza e adequação aos maquinários utilizados e existência ou não de experiência prévia na execução da operação.

O número de equipes (ou trabalhadores) a ser analisado depende da adequação de cada equipe às condições exigidas para modelagem por curva de aprendizado e da disponibilidade de meios para a coleta de dados. Esses meios se referem a pessoas capacitadas para a realização das coletas, existência de materiais adequados (marcadores de tempo, leitores digitais, entre outros) e tempo suficiente dentro das etapas de execução do estudo. As equipes de trabalhadores formadas passam a ser identificadas pelo índice i , tal que $i = 1, \dots, I$.

3.3 CRUZAMENTO ENTRE AS EQUIPES DE TRABALHADORES E AS FAMÍLIAS DE PRODUTOS

As J famílias de produtos formadas são cruzadas com as I equipes de trabalhadores selecionadas como amostra. A idéia chave é obter dados de desempenho de cada equipe na execução de operações “gargalo de aprendizado” relativas a cada família de produtos. Gargalo de aprendizado pode ser definido como a operação mais complexa no processo de fabricação do produto, demandando um elevado número de repetições para que os preceitos de execução sejam assimilados pelo trabalhador. Os dados de desempenho (totalizando $I \times J$ coletas de dados, no caso de monitorar uma operação por equipe, com apenas uma repetição) são expressos como taxa de produção (número de unidades produzidas por tempo de operação), atendendo à unidade de entrada demandada pelos modelos de curvas de aprendizado a serem avaliados na modelagem [equações (13), (14) e (16)].

Os dados de desempenho de uma equipe de trabalhadores podem ser coletados de todos os componentes da equipe – situação ideal - ou de membros cujas operações são consideradas importantes. A escolha de operações “gargalo” permite inferir conclusões quanto à adequação de todos os integrantes da equipe frente à família de produtos em questão, visto que as operações subsequentes dependem do processamento da operação que apresenta maiores dificuldades. Quando a operação analisada for executada por dois ou mais trabalhadores é possível selecionar um trabalhador de desempenho intermediário para a coleta de dados. A escolha de um trabalhador com desempenho médio visa eliminar a possibilidade de superestimação ou subestimação do potencial da equipe, sendo efetuada com o auxílio de especialistas do processo.

A definição prévia da operação “gargalo” a ser monitorada é fundamental para que a coleta seja iniciada na primeira unidade produzida, capturando integralmente o processo de aprendizado do trabalhador. A identificação da operação realizada após o início do processo acarreta perda de informação relativa às primeiras unidades produzidas, prejudicando a análise do aprimoramento de desempenho. Operações “gargalo” podem ser identificadas com o auxílio de especialistas.

Uma forma alternativa de coleta é o monitoramento da produção final da equipe, através da contagem do número de produtos que deixam o processo. Os dados coletados nessa posição devem ser similares aos valores extraídos da operação “gargalo”.

A coleta dos dados de desempenho da operação “gargalo” deve obedecer a uma sistemática definida. É necessário que o procedimento tenha início nos primeiros ciclos de fabricação do produto e seja realizado até alcançar um número de dados que viabilize a modelagem através de curvas de aprendizado. A duração ideal do período de coleta é aquela em que a produtividade horária atinge um estado estacionário, sinalizando que o processo de aprendizado do trabalhador está próximo da conclusão.

A duração do período de coleta, entretanto, pode ser diferente de equipe para equipe atuando em produtos pertencentes a uma mesma família, o que é justificado pelos perfis de aprendizado distintos apresentados pelas equipes. Variações nos perfis podem ser decorrentes de diferentes graus de destreza, treinamento ou experiência prévia associados ao produto. A modelagem do desempenho de trabalhadores que não concluíram a maior parte do seu processo de aprendizado prejudica a precisão dos parâmetros gerados pela curva e, para fins de alocação, pode levar a conclusões imprecisas.

A coleta é operacionalizada através da contagem do número de unidades produzidas em cada intervalo de tempo de operação, podendo ser realizada através de contadores eletrônicos ou com o auxílio de planilha e cronômetro. Produtos em processamento no momento do fechamento de um intervalo são automaticamente computados no intervalo seguinte. A utilização de intervalos de mesma duração permite comparar a taxa de produção de diferentes equipes no mesmo instante de tempo depois de iniciado o processo, além de facilitar a modelagem. A Figura 14 apresenta um detalhamento do arranjo dos dados de desempenho coletados.

		Desempenho (unidades/tempo de operação)			
		<i>Produto 1</i>	<i>Produto 2</i>	<i>Produto n</i>
Tempo de operação (intervalos de t minutos)	t_1				
	t_2				
	⋮				
	t_n				

Figura 14: Arranjo dos dados de desempenho coletados para cada produto

Alguns ambientes de produção submetidos a trocas freqüentes de produtos apresentam dificuldades extras para a coleta dos dados. Ajustes nas máquinas e nos procedimentos de operação dos trabalhadores podem ser necessários durante os primeiros ciclos de produção, o que acaba por gerar paradas não programadas durante a coleta dos dados. Essas paradas geram períodos ociosos dentro dos intervalos de coleta, reduzindo o número de unidades produzidas por intervalo e distorcendo os dados de desempenho do trabalhador.

Uma alternativa para minimizar os efeitos das pequenas paradas é a medição do tempo demandado para execução de cada unidade (tempo/unidade) e a posterior conversão desses tempos na forma de taxa de produção (unidades/tempo). Dessa forma, os tempos são somados até preencherem a duração estabelecida para o intervalo, sendo o número de unidades incluídas naquele intervalo o total de unidades produzidas. O arranjo do tempo efetivamente trabalhado em intervalos de operação reproduz a condição normal de processo, na qual o trabalhador segue imediatamente para a próxima unidade após a conclusão da unidade que está sendo executada.

Outra forma de eliminar o problema é a formação de pequenos estoques de componentes aguardando processamento em frente à operação analisada. Os estoques garantem atividade para a operação, enquanto soluções são encaminhadas para a normalização das operações anteriores.

Os cruzamentos entre equipes e famílias de produtos devem ser repetidos para gerar uma estimativa do erro experimental (MONTGOMERY, 1991), o que permite a análise da variabilidade dos dados e eliminação de valores espúrios. Coletas executadas sobre diferentes modelos pertencentes a uma mesma família podem ser consideradas repetições, dadas as características similares dos produtos que a compõem. Tal suposição facilita a coleta de dados, já que impõe a repetição da coleta dentro da família de produtos e não necessariamente de um produto em particular. Em situações reais, um determinado produto pode apresentar pequena demanda, vindo a ser produzido esporadicamente. A necessidade de coletar dados de várias partidas de produção de um produto com essas características geraria empecilhos à coleta de dados.

Os dados de desempenhos, expressos na forma de unidades produzidas por tempo, são modelados através de curvas de aprendizado.

3.4 MODELAGEM DOS DADOS DE DESEMPENHO OBTIDOS NOS CRUZAMENTOS ATRAVÉS DE MODELOS DE CURVAS DE APRENDIZADO APRESENTADOS NA LITERATURA

Para uma comparação mais restrita, optou-se por 3 modelos de curvas cuja variável de resposta é expressa em número de unidades produzidas por tempo de operação. Os modelos de curvas de aprendizado utilizados foram selecionados segundo suas capacidades de aderência aos dados e significado dos parâmetros que os compõem.

Os modelos hiperbólico de 3 parâmetros e exponencial de 3 parâmetros [equações (16) e (13), respectivamente] foram escolhidos tomando-se por base a classificação de Uzumeri e Nembhard (2000a), segundo a qual essas equações apresentam os melhores resultados de eficiência e estabilidade frente aos demais modelos analisados (ver Tabela 1). Os parâmetros que compõem as duas equações (k , p e r) apresentam significados idênticos, possibilitando comparações diretas entre os resultados obtidos pelas modelagens.

A terceira equação testada é o modelo de tempo constante [equação (14)], sendo sua estrutura matemática similar ao modelo exponencial. Os parâmetros constituintes da equação de tempo constante (Y_c , Y_f e τ) possuem definições distintas dos parâmetros dos modelos hiperbólico e exponencial. Mesmo assim, há analogia entre o significado prático dos parâmetros, de forma a possibilitar comparações entre os resultados das modelagens oriundas das três equações. O Quadro 3 apresenta as equivalências de significado dos parâmetros constituintes das três equações selecionadas para as modelagens.

SIGNIFICADO DO PARÂMETRO	MODELO		
	HIPERBÓLICO-3	EXPONENCIAL-3	TEMPO CONSTANTE
Desempenho final	k	k	y_f
Experiência prévia	p	p	y_c
Taxa de aprendizado	r	r	τ

Quadro 3: Significado dos parâmetros dos modelos de curvas de aprendizado avaliados

Os parâmetros das equações (13), (14) e (16) são obtidos através de regressão não-linear por intermédio de *software* de análise estatística (SPSS, Statgraphics, entre outros). Casos em que a modelagem não apresenta convergência imediata, comuns na regressão não-linear, podem ser solucionados através da modificação nos valores iniciais dos parâmetros. Os

dados de desempenho são modelados como variável dependente (y) do tempo acumulado de atuação do trabalhador na operação analisada (x).

Os critérios utilizados para avaliar a aderência dos modelos de curvas de aprendizado aos dados de desempenho são: (i) soma dos quadrados dos erros (SQE), sendo os erros obtidos pela diferença entre os valores reais e os preditos pela curva; (ii) coeficiente de determinação; e (iii) capacidade preditiva das curvas em uma amostra de validação, mensurada através do percentual de desvio entre o valor predito pelas curvas para um instante de operação em estado estacionário e o valor real obtido em uma amostra de validação.

A análise dos três critérios permite selecionar o modelo de curva de aprendizado mais adequado para descrição do desempenho das equipes de trabalhadores nas operações analisadas.

As etapas seguintes referem-se aos procedimentos e análises realizados sobre os parâmetros do modelo de curva de aprendizado selecionado. Os parâmetros do modelo escolhido serão identificados por k , p e r , de maneira a uniformizar a linguagem e facilitar o entendimento da função de cada parâmetro (ou seja, mesmo no modelo de tempo constante, os parâmetros serão designados por k , p e r , de acordo com as correspondências indicadas no Quadro 3.

Os parâmetros k , p e r permitem estimar o desempenho final, a experiência prévia e a taxa de aprendizado de cada equipe operando sobre cada família de produtos, respectivamente. Assim, uma família de produtos j gera um conjunto de parâmetros k_{ij} , p_{ij} e r_{ij} , referente a i -ésima equipe de trabalhadores. A comparação desses parâmetros para diferentes valores de i e j possibilita avaliar a adequação das famílias de produtos às equipes.

O parâmetro k permite estimar o desempenho final do trabalhador em unidades produzidas por tempo de operação quando seu processo de aprendizado estiver concluído, ou seja, os preceitos de execução da operação estiverem integralmente assimilados. Valores elevados de k representam alto patamar de desempenho final. Sua utilização como indicador para alocação de trabalhadores a produtos se justifica em corridas longas de produção, onde elevados índices de desempenho final são desejados. Corridas curtas (características de lotes pequenos) geralmente não permitem que o trabalhador execute o número de unidades necessárias para atingir tal padrão de desempenho. Nesses casos, a utilização do parâmetro k para o direcionamento de produtos às equipes de trabalhadores não é indicada, sendo recomendada a utilização do parâmetro r , conforme detalhado mais adiante.

O parâmetro p quantifica a experiência prévia do trabalhador na tarefa em questão ou em atividades similares. Valores elevados de p indicam que o trabalhador analisado apresenta alto desempenho nos primeiros ciclos de produção. A análise de p permite direcionar trabalhadores mais experientes a operações mais complexas, em corridas de durações distintas.

Uzumeri e Nembhard (1998) definem o parâmetro r como o tempo acumulado de operação necessário para que o trabalhador atinja metade do patamar máximo de desempenho ($k/2$) na execução de uma operação. Na prática, o parâmetro r pode ser interpretado como a taxa de aprendizado do trabalhador, sendo que menores valores de r indicam a necessidade de menor tempo de operação para obtenção de k , significando um aprendizado mais rápido (ver seção 2.3.4). Assim, o parâmetro r , analisado isoladamente, pode ser utilizado como um indicador da adaptação de equipes de trabalhadores a corridas curtas de produção (lotes pequenos). Para corridas longas, entretanto, a influência dos demais parâmetros deve ser considerada para a obtenção de resultados mais confiáveis.

3.5 ANÁLISE DOS PARÂMETROS GERADOS PELA CURVA DE APRENDIZADO SELECIONADA

A análise dos parâmetros oriundos da modelagem se dará de duas maneiras, de acordo com a duração da corrida de produção: análise do parâmetro r de forma isolada, voltada para corridas de produção de curta duração, e análise das curvas originadas pelas modelagens, aplicável em corridas de durações distintas. A estimativa da duração da corrida de produção pode ser feita através da programação de produção da empresa, dividindo-se o tamanho do lote a ser produzido pela capacidade de produção conhecida. Cabe aos especialistas classificarem as durações em curtas ou longas, de acordo com o ambiente estudado. Por exemplo, pode-se definir uma corrida curta como aquela que se completa em menos de um dia de trabalho, não demandando múltiplos *setups* por parte do operador. Tal definição, entretanto, está claramente condicionada ao grau de dificuldade, em termos de aprendizagem, dos produtos considerados na análise.

3.5.1 Análise de Regressão sobre o Parâmetro de Taxa de Aprendizado (r) resultante da modelagem

A identificação de trabalhadores que se adaptam com maior rapidez às operações demandadas surge como alternativa preferencial para alocação aos produtos cuja corrida de produção é curta, independente do desempenho final apresentado por esses trabalhadores. Tais corridas não oferecem tempo de operação suficiente para que trabalhadores com reduzida experiência atinjam o patamar de desempenho máximo na operação, desaconselhando a utilização do parâmetro k na alocação dos produtos às equipes. Dessa maneira, deseja-se uma forma de análise que priorize o parâmetro r .

Propõe-se relacionar o parâmetro r através de um modelo de regressão linear múltipla, com as seguintes variáveis independentes: (i) equipe de trabalhadores (X_1), (ii) família de produtos (X_2), e (iii) interação entre equipe de trabalhadores e família de produtos (X_1X_2). O modelo é apresentado na equação (29).

$$r_{ij} = b_0 + b_1X_1 + b_2X_2 + b_3X_1X_2 \quad (29)$$

O parâmetro r_{ij} é a variável dependente do modelo de regressão, onde i representa a equipe e j representa a família de produto considerada. As variáveis X_1 e X_2 são substituídas por escalas codificadas de números inteiros positivos referentes a cada equipe de trabalhadores e a cada família de produtos, respectivamente (as escalas codificadas são apresentadas no Quadro 4). Os valores de escala devem estar atrelados aos níveis dos indicadores da equipe ou do produto em questão, ou seja, elevados valores de escala devem indicar elevados níveis do indicador. De tal forma, os níveis de determinada característica da equipe ou do produto são mantidos e representados de forma facilitada. O valor da variável X_1X_2 é obtido através da multiplicação das variáveis X_1 e X_2 , representando a interação entre equipe e família de produtos.

Conforme explicitado acima, a regressão busca estabelecer uma equação que possibilite estimar a taxa de aprendizado (r) de forma facilitada, dispensando sucessivas modelagens através de curvas de aprendizado quando se opera com um grande número de produtos e equipes, o que inviabilizaria a observação de todos os cruzamentos possíveis. A elaboração de um modelo de regressão também é útil em casos de alteração do produto em

processo, permitindo estimar a taxa de aprendizado das equipes sobre aquele produto sem a necessidade de coleta de dados e modelagem através de curva de aprendizado.

TRABALHADORES		PRODUTOS	
EQUIPES	X_1	FAMÍLIAS	X_2
Equipe 1	1	Família 1	1
Equipe 2	2	Família 2	2
⋮	⋮	⋮	⋮
Equipe I	I	Família J	J

Quadro 4: Escala codificada para equipes de trabalhadores (X_1) e famílias de produtos (X_2)

A determinação das constantes b_0 , b_1 , b_2 e b_3 na equação (29) pode ser realizada através de *software* de análise estatística (SPSS, Statgraphics, entre outros). A determinação das constantes permite avaliar a significância de cada variável independente e a magnitude da sua influência sobre a taxa de aprendizado do trabalhador.

A regressão obtida possibilita a estimativa de r_i para i equipes candidatas à fabricação de um determinado produto (isto é, para um dado valor de X_2), através da substituição do valor de escala correspondente a cada equipe ($X_1 = 1, \dots, I$) na equação (29). Assim, dispondo-se de quantidade suficiente de informações, pode-se estimar r_{ij} para determinados cruzamentos sem a necessidade de coleta de dados e modelagem pelas curvas de aprendizado. O menor valor de r_{ij} obtido refere-se à equipe que apresenta a melhor taxa de aprendizado para a família de produtos em questão, sendo a mais recomendada para a execução da operação.

Novos produtos com características distintas e que não se inserem nas famílias previamente formadas demandam uma nova coleta de dados e posterior modelagem através de curvas de aprendizado, visto que as características das novas operações podem gerar perfis de aprendizado distintos dos obtidos para as famílias já existentes. De forma análoga, as constantes da equação (29) deverão ser recalculadas considerando as novas famílias de produtos.

O ingresso de nova equipe de trabalhadores apta à execução das operações demandadas é analisado de maneira semelhante. Produtos pertencentes às famílias já existentes devem ser direcionados à nova equipe para ampliação do banco de dados de

desempenho e modelagem através de curvas de aprendizado. Novamente, os parâmetros da equação (29) deverão ser atualizados.

3.5.2 Análise das Curvas de Aprendizado construídas a partir dos Parâmetros gerados pela Modelagem

Existem situações em que os lotes de produção são compostos por um número de unidades suficiente para que o trabalhador atinja o estado estacionário de desempenho na execução das tarefas. O monitoramento do processo de aprendizado, nessa condição, se torna mais preciso com a análise do conjunto de parâmetros gerados pelas modelagens das curvas de aprendizado.

O parâmetro r mantém sua importância na descrição da velocidade de adaptação da equipe ao produto. O desempenho final (k) e a experiência prévia (p) passam a ser relevantes, visto que o período de fabricação do produto é maior. Equipes que apresentam elevadas taxas de aprendizado (característica desejada em corridas curtas) podem não atingir patamares de desempenho proporcionais em corridas longas de produção. Ao mesmo tempo, equipes que demandam maior tempo de aprendizado em uma operação podem alcançar maiores níveis de desempenho final, resultado esse mais apropriado para operação em grandes lotes. Tais comportamentos distintos podem ser avaliados através das curvas de aprendizado de cada equipe.

Propõe-se o seguinte procedimento para análise das curvas de aprendizado e direcionamento de equipes de trabalhadores à famílias de produtos. As curvas de aprendizado a serem analisadas são construídas a partir dos parâmetros \bar{k}_{ij} , \bar{p}_{ij} e \bar{r}_{ij} , obtidos através da média dos parâmetros gerados pelas modelagens da i -ésima equipe na execução de produtos pertencentes à j -ésima família. Assim, cada equipe possui um conjunto de parâmetros médios que permitem avaliar o processo de aprendizado e efetuar previsões de desempenho para horizontes de tempos variados. A utilização de parâmetros médios busca capturar os vários comportamentos de desempenho apresentados por uma equipe atuando em produtos de uma mesma família, incorporando eventuais variações de desempenho.

A abscissa das curvas geradas representa o tempo de operação na tarefa analisada e a ordenada indica o número de unidades produzidas por tempo de operação. A representação da ordenada em unidades produzidas é adequada quando os tempos de execução das operações

analisadas são semelhantes, o que resulta em níveis de produção similares e, por consequência, na proximidade das curvas em um gráfico comparativo (exemplificado na Figura 15).

A análise do aprendizado é feita através da comparação do nível de produção previsto pela curva de aprendizado gerada para cada equipe atuando sobre dada família de produtos. A avaliação visual da curva, entretanto, não é suficiente para quantificar de forma precisa a produção alcançada pelas equipes com o avanço do processo. Assim, a avaliação é realizada pela comparação das áreas formadas sob as curvas de aprendizado das equipes monitoradas. As áreas podem ser obtidas através da integração da equação da curva selecionada, podendo ser realizada de forma numérica ou analítica.

A integração numérica pode ser realizada através de um método numérico conhecido (Simpson, Newton-Raphson, entre outros), enquanto que a integração analítica demanda a determinação da primitiva da curva de aprendizado utilizada. O procedimento de análise é idêntico para as duas formas de integração.

A análise do resultado da integração das curvas de aprendizado para uma dada família de produtos e diferentes equipes de trabalhadores vem exemplificada na Figura 15, para o caso de duas equipes. O resultado da integração das curvas vem representado por A_i , onde i designa a equipe. Seja T a variável aleatória que designa o tempo de operação. O gráfico apresenta duas divisões, a partir do tempo de operação $T = t$. Quando $T < t$, $A_1 > A_2$ e o produto deve ser direcionado à Equipe 1, evidenciado pelo crescimento mais acentuado da sua curva em direção ao desempenho final k_1 . Quando $T > t$, $A_2 > A_1$ e o produto deve ser alocado à Equipe 2. É interessante ressaltar que a Equipe 2 apresenta um aprendizado mais lento, compensado por um maior desempenho final para horizontes longos de produção. Finalmente, quando $T = t$, $A_1 = A_2$ e as equipes apresentam o mesmo desempenho.

Conforme ilustrado na Figura 15, a comparação das áreas permite obter o instante $T = t$ em que o nível de produção de uma equipe que apresenta maior taxa de aprendizado e menor desempenho final é igualada ao de outra equipe com maior r_{ij} e maior k_{ij} (ou seja, aprendizado mais lento, porém alcançando maior desempenho final). Esse instante t é determinado quando a área sob as duas curvas atinge o mesmo valor, conforme exemplificado na Tabela 2. Os valores grifados em negrito apontam a equipe que deve executar a operação de acordo com o tempo de duração da mesma (os valores apresentados na Tabela 2 são ilustrativos).




Figura 15: Análise das áreas geradas pelas curvas para uma família de produtos X

Tabela 2: Áreas geradas pela integral da curva de aprendizado para duas equipes

Área sob a curva de aprendizado		
Tempo de operação(min)	Equipe 1 (A1)	Equipe 2 (A2)
60	94,6	53,2
120	251,0	163,0
180	425,7	304,3
240	609,3	465,5
300	798,2	640,6
360	990,7	826,0
420	1185,7	1019,1
480	1382,5	1218,3
540	1580,8	1422,6
600	1780,3	1631,0
660	1980,8	1842,9
720	2182,0	2057,7
780	2383,9	2275,1
840	2586,4	2494,7
900	2789,4	2716,3
960	2992,9	2939,6
1020	3196,7	3164,5
1080	3400,9	3390,7
1140	3605,3	3618,2
1200	3810,1	3846,8
1260	4015,1	4076,5
1320	4220,3	4307,1
1380	4425,7	4538,6
1440	4631,4	4770,9

Instante t em que a produção da Equipe 2 supera a da Equipe 1

Casos em que as curvas de aprendizado são organizadas de forma alternativa em um gráfico (por exemplo, uma única equipe atuando sobre as J famílias de produtos) têm sua análise conduzida de forma análoga à acima descrita.

Equipes cujas curvas de aprendizado não apresentam interseção são mais simples de serem alocadas, pois a curva da equipe de melhor desempenho conduzirá ao maior valor de área para todos os tempos de operação analisados.

Existem situações em que os tempos de execução demandados por diferentes modelos de produtos dentro de uma mesma família apresentam valores discrepantes entre si. Essa discrepância gera valores de k_{ij} de grandezas diversas, fazendo com que o cálculo de \bar{k}_{ij} não represente o patamar final de desempenho da família em questão de maneira adequada. Uma forma alternativa de representar \bar{k}_{ij} é relacionar cada k_{ij} oriundo da modelagem de determinado produto com a produção programada pela empresa para aquele modelo de produto, gerando k'_{ij} (parâmetro de desempenho final relativo). Esse procedimento justifica-se na consideração de que a produção programada pela empresa (em unidades por intervalo de tempo) é inversamente proporcional ao tempo de execução demandado por cada modelo de produto, ou seja, operações cujo tempo de execução é curto conduzem a valores elevados de k_{ij} , os quais são diluídos em valores também elevados de produção programada.

Na conversão acima proposta, o valor de k_{ij} para um produto (obtido pela modelagem e expresso em unidades por intervalo de tempo) é dividido pela produção programada da empresa para intervalos de mesma duração. Por exemplo, um lote de produção programado de 800 unidades por dia corresponde a aproximadamente 17 unidades a serem produzidas por intervalo de 10 minutos de produção, em um regime de 8 horas de trabalho por dia. Sendo o parâmetro k_{ij} gerado pelas modelagens igual a 25 unidades produzidas a cada 10 minutos de operação, obtém-se um k'_{ij} igual a 1,5 (25/17). Esse valor passa a representar a ordenada do gráfico de desempenho (exemplificado pela Figura 15) e será utilizado nos procedimentos de integração. Episódios onde existam repetidas atuações da equipe i em produtos de uma família j demandam a estimativa de \bar{k}'_{ij} , obtido pela média de k'_{ij} para os produtos de uma mesma família.

A análise das curvas expressas em escala de desempenho relativo é realizada de forma análoga às curvas em que o desempenho é apresentado na forma de unidades produzidas por

tempo de operação. A equipe cuja curva apresentar maior área é escolhida para a execução da tarefa.

3.6 ALOCAÇÃO DAS FAMÍLIAS DE PRODUTOS ÀS EQUIPES DE TRABALHADORES

Ambientes com grande flexibilidade de catálogo são caracterizados pela alternância de modelos de produtos e de duração das corridas de produção. Essa condição exige rápida adequação das equipes às novas características do produto demandado.

Produtos cuja corrida de produção é extremamente curta podem ser alocados às equipes mais habilitadas através da análise isolada do parâmetro r oriundo da regressão linear múltipla. O parâmetro r aponta o tempo de operação necessário para que a equipe atinja determinado patamar de desempenho. A equipe detentora do menor valor de r dentre as equipes candidatas apresenta a melhor taxa de aprendizado, sendo escolhida para a execução dos produtos pertencentes àquela família.

A análise das curvas de aprendizado construídas a partir dos parâmetros médios possibilita uma avaliação mais robusta e abrangente para o direcionamento dos produtos às equipes, visto que podem ser utilizadas para variadas durações de corrida de produção. O nível de produção atingido pelas equipes é avaliado através da área formada sob cada curva representativa do desempenho de uma equipe. A equipe que possuir a maior área em determinado tempo t de produção (valor vinculado ao tempo de duração da corrida) é a mais apropriada para execução das operações relativas aos produtos daquela família.

CAPÍTULO 4

4 ESTUDO DE CASO

Este capítulo destina-se à descrição do estudo de caso definido para essa dissertação. A metodologia proposta no Capítulo 3 foi aplicada em uma empresa exportadora do setor calçadista.

O processo de fabricação de calçados é composto por aproximadamente 100 operações, alternando atividades manuais com procedimentos automatizados. O processo pode ser dividido nos setores de corte, costura, montagem e acabamento, conforme brevemente descrito na sequência. O setor de costura foi selecionado para a elaboração deste estudo de caso.

O setor de corte é responsável pelo corte da matéria-prima que irá compor o cabedal (parte superior do calçado) e o solado. As peças são cortadas manualmente com a ajuda de navalhas ou através de prensa hidráulica, denominada balancim de corte. A operação demanda cuidados especiais em relação ao sentido de corte das fibras do material, existência de defeitos e de variações de espessura, entre outros.

No setor de costura é realizada a união das partes constituintes do calçado. As principais tarefas dizem respeito a atividades de colagem, dobra e chanfração, sendo parte dessas tarefas realizadas com o auxílio de máquinas ou instrumentos específicos. O setor de costura normalmente representa o gargalo da operação, dada a diversidade de tarefas e de tempos de ciclos que compõem as operações (PICCININI, 1992).

Na etapa de montagem, o cabedal é fixado ao solado. A maior parte das operações desse setor é realizada com o auxílio de máquinas, dada a dificuldade dos procedimentos de união das partes do calçado.

O setor de acabamento finaliza o processo de fabricação do calçado. Excessos de cola são eliminados através de escovação e pequenas falhas são corrigidas por intermédio de ajustes manuais (COSTA, 1993). O produto é então embalado e expedido.

O controle de qualidade é realizado através de amostragem em vários pontos da linha de produção. A inspeção é feita por trabalhadores treinados da própria linha.

Os dados obtidos na empresa, com relação às informações do processo e produtos em estudo, possibilitaram a aplicação do método proposto para o direcionamento de famílias de calçados às linhas de produção.

A seguir será apresentada a aplicação das etapas constituintes do método proposto no Capítulo 3 desta dissertação aos dados do estudo de caso.

4.1 IDENTIFICAÇÃO E AGRUPAMENTO DOS PRODUTOS COM CARACTERÍSTICAS SIMILARES

O número elevado de modelos de calçados em produção na empresa demandou o agrupamento dos mesmos em famílias com características semelhantes, com o propósito de reduzir a coleta de dados e simplificar a análise.

Foram selecionados pelos especialistas da empresa 30 modelos de calçados representativos da produção. Cada modelo foi classificado segundo características de complexidade dos seus procedimentos de costura, permitindo a construção de uma matriz relacionando Modelo de calçado *versus* Características de complexidade avaliada. Essa matriz foi preenchida por 3 especialistas do setor de costura, utilizando uma escala numérica de 1 a 3, onde 3 indica alta complexidade do calçado referente à característica analisada. As características de complexidade avaliadas, bem como os valores atribuídos, são apresentadas na Tabela 3.

A matriz Modelo de calçado *versus* Características de complexidade foi submetida a rotinas de clusterização, com auxílio do *software* SPSS v. 8.0. Utilizou-se uma rotina não-hierárquica, através do procedimento *k-means*, sendo a medição de similaridade baseada na distância Euclidiana dos valores atribuídos às características dos calçados. A idéia-chave era

agrupar modelos de calçados com características similares de complexidade em uma mesma família, formando famílias com características distintas entre si.

Foram geradas 3 famílias de modelos. Analisando as características de complexidade dos modelos agrupados nas famílias, foi possível rotulá-las como *Fácil*, *Média* e *Difícil*. Os primeiros dez modelos (*Calçado 1* ao *Calçado 10*), entretanto, não foram modelados através de curvas de aprendizado, já que não havia demanda de produção para tais modelos, o que impossibilitou a coleta de dados. Os *Calçados 1* a *10* foram, então, incluídos nas famílias formadas por serem modelos importantes no contexto de produção da empresa. Os *Calçados 11* a *30*, com produção prevista para os próximos meses, foram destinados à modelagem por curvas de aprendizado. A Tabela 3 apresenta a família a que cada modelo de calçado foi alocado.

Tabela 3: Matriz dos atributos dos calçados analisados e família a que cada modelo foi alocado

CALÇADO	CARACTERÍSTICAS							FAMÍLIA
	Complexidade	Costura	Enfeite	Forro	Material	nº Peças	Sap/outro	
Calçado 1	1	1	2	1	1	1	2	FÁCIL
Calçado 2	2	2	2	1	1	2	2	FÁCIL
Calçado 3	1	1	1	1	1	2	2	FÁCIL
Calçado 4	2	2	2	1	1	2	2	FÁCIL
Calçado 5	2	1	2	2	1	2	1	MÉDIA
Calçado 6	2	1	3	2	1	1	1	MÉDIA
Calçado 7	2	1	2	2	1	2	1	MÉDIA
Calçado 8	3	3	3	3	3	3	2	DIFÍCIL
Calçado 9	3	3	3	3	2	2	2	DIFÍCIL
Calçado 10	2	2	2	2	3	3	1	DIFÍCIL
Calçado 11	1	1	1	1	1	2	2	FÁCIL
Calçado 12	2	1	1	2	2	1	1	FÁCIL
Calçado 13	1	1	1	2	1	1	2	FÁCIL
Calçado 14	2	2	1	1	1	2	1	FÁCIL
Calçado 15	1	1	2	2	1	2	1	FÁCIL
Calçado 16	1	1	1	1	1	1	1	FÁCIL
Calçado 17	2	1	1	1	2	1	1	FÁCIL
Calçado 18	2	2	3	1	1	1	1	MÉDIA
Calçado 19	2	2	2	1	2	2	1	MÉDIA
Calçado 20	2	2	2	1	2	1	1	MÉDIA
Calçado 21	2	1	3	1	1	2	1	MÉDIA
Calçado 22	2	2	2	1	2	2	1	MÉDIA
Calçado 23	2	1	2	1	2	2	1	MÉDIA
Calçado 24	2	1	2	1	2	2	1	MÉDIA
Calçado 25	3	2	3	2	3	2	1	DIFÍCIL
Calçado 26	3	1	3	2	3	2	1	DIFÍCIL
Calçado 27	2	2	2	2	2	3	1	DIFÍCIL
Calçado 28	2	2	3	2	3	2	1	DIFÍCIL
Calçado 29	2	2	3	2	2	2	2	DIFÍCIL
Calçado 30	3	2	3	2	2	3	1	DIFÍCIL

Na seqüência, os modelos foram direcionados a equipes de trabalhadores cujas características de operação fossem adequadas para execução das tarefas demandadas. O procedimento de seleção das equipes é apresentado na seqüência.

4.2 IDENTIFICAÇÃO DA AMOSTRA DE TRABALHADORES A SER USADA NA COLETA DE DADOS

Selecionaram-se 3 equipes de trabalhadores do setor de costura, cada qual pertencente a uma linha de produção distinta, com o propósito de coleta de dados. As equipes foram selecionadas segundo os seguintes critérios: (i) análise dos indicadores de desempenho de produção fornecidos pela empresa (% atingido da produção programada, % de retrabalho e indicador de aproveitamento de couro, entre outros), o que permitiu apontar as equipes com

desempenho destacado; (ii) indicação de supervisores de produção; e (iii) número de trocas de modelos de calçados programadas para o período de coleta de dados, priorizando-se as equipes que seriam submetidas ao maior número de alterações. As equipes selecionadas foram identificadas por *Equipe 1*, *Equipe 2* e *Equipe 3*.

As equipes analisadas eram compostas por aproximadamente 40 integrantes e apresentavam formação consolidada, ou seja, seus trabalhadores não eram substituídos ou submetidos à execução de outras operações dentro da mesma equipe com frequência. A rotatividade dos membros das equipes analisadas era inferior a 2%, indicando reduzidas modificações nos seus integrantes e evitando alterações no perfil de aprendizado durante a análise. Os membros das equipes selecionadas haviam recebido treinamento e contavam com experiência na execução dos modelos de calçados fabricados.

Às equipes selecionadas foram direcionadas as famílias de calçados, com o propósito de coletar dados de desempenho da atuação de cada equipe sobre os modelos das 3 famílias formadas. O procedimento de coleta de dados é apresentado na próxima seção.

4.3 CRUZAMENTO ENTRE AS EQUIPES DE TRABALHADORES E AS FAMÍLIAS DE PRODUTOS

Os modelos de calçados a serem analisados (*Calçado 11* ao *Calçado 30*) foram direcionados às equipes de trabalhadores obedecendo à programação de produção definida pela empresa. Os dados de desempenho foram coletados através do monitoramento do trabalhador responsável pela execução da operação “gargalo” de cada calçado, sendo essa operação pertencente ao setor de costura e indicada por especialistas.

A definição da operação a ser monitorada era feita antes do início da produção do novo calçado, visando não perder os dados de desempenho das primeiras unidades produzidas. Para isso, os especialistas listavam duas ou mais operações passíveis de formação de gargalo na execução do calçado em questão, sendo escolhida uma, de forma aleatória, para a coleta dos dados. Dessa forma, o procedimento de coleta estaria sendo feito em uma operação com potencial risco de problema (mesmo não sendo o principal gargalo) e não seriam perdidos os dados das primeiras unidades produzidas. O Quadro 5 apresenta a operação de costura analisada em cada calçado.

A operação gargalo poderia ser composta por mais de um posto de trabalho, ou seja, dois ou mais trabalhadores da mesma equipe executando a operação a ser analisada. Essa situação é verificada quando o tempo de ciclo da operação é elevado, demandando a utilização de trabalhadores em paralelo na linha de montagem. Nesses casos, selecionava-se um trabalhador de desempenho intermediário para a coleta dos dados. Essa indicação era fornecida por especialistas.

CALÇADO	OPERAÇÃO
<i>Calçado 11</i>	Fazer virado (c/máquina)
<i>Calçado 12</i>	Preparar gáspea
<i>Calçado 13</i>	Costurar forro na gáspea
<i>Calçado 14</i>	Preparar o cano da bota
<i>Calçado 15</i>	Fazer virado nas laterais e boca do corte (com máquina)
<i>Calçado 16</i>	Fazer virado da gáspea
<i>Calçado 17</i>	Preparar a gáspea
<i>Calçado 18</i>	Costurar a gáspea
<i>Calçado 19</i>	Preparar enfeite da gáspea
<i>Calçado 20</i>	Costurar enfeite da gáspea
<i>Calçado 21</i>	Preparar fecho no traseiro
<i>Calçado 22</i>	Preparar tira do traseiro.
<i>Calçado 23</i>	Preparar tira do traseiro.
<i>Calçado 24</i>	Preparar enfeite da gáspea
<i>Calçado 25</i>	Preparar gáspea no cano
<i>Calçado 26</i>	Colar corrente no traseiro
<i>Calçado 27</i>	Preparar forro na gáspea e fazer riscado
<i>Calçado 28</i>	Preparar enfeite da gáspea
<i>Calçado 29</i>	Preparar o pala (virado)
<i>Calçado 30</i>	Preparar as 4 tiras superiores da gáspea (com matriz)

Quadro 5: Operação de costura monitorada para cada calçado

A coleta dos dados de desempenho poderia ser realizada através da contagem do número de pares de calçados produzidos por tempo de operação ou pela medição do tempo demandado para cada par, conforme apresentado na seção 3.3. Apesar de a primeira forma de coleta fornecer dados prontos para a modelagem pelas curvas de aprendizado a serem avaliadas, a segunda forma foi a escolhida, dadas as características das operações analisadas.

As operações ligadas à costura demandam grande número de ajustes nos primeiros instantes de produção, o que prejudica a precisão da primeira forma de coleta apresentada (pares/tempo). A simples contagem do número de pares produzidos em um intervalo de tempo acaba por considerar válidos os instantes em que o trabalhador está parado em razão dos

procedimentos de ajustes em sua operação ou em postos anteriores. Os dados gerados nessa condição apresentam grande variabilidade e não retratam as características normais do processo, no qual os trabalhadores concluem as operações de um par de calçados e passam imediatamente para outro.

A formação de pequenos estoques de componentes esperando processamento na frente da operação analisada, forma de manter o trabalhador monitorado em atividade, mostrou-se inviável, dadas as limitações de espaço.

A medição dos dados de desempenho em segundos/par de calçado produzido, de acordo com a segunda forma de coleta apresentada na seção 3.3, foi selecionada e feita com o auxílio de cronômetro e planilha, sendo realizada por um especialista na área de coleta de tempo. Cada ciclo era iniciado quando o trabalhador retirava o calçado a ser processado da esteira e finalizado quando o produto processado era devolvido à ela. O processo de coleta tinha início na primeira unidade da nova corrida de produção e era interrompido quando não houvesse variações significativas no tempo demandado para execução de um par. A duração média do período de coleta para os calçados analisados foi de 3 horas.

Os dados coletados (tempo/par) foram convertidos em taxa de produção (pares/tempo), através do arranjo dos tempos de execução e do número de pares produzidos em intervalos de tempo de operação padrão. Adotaram-se intervalos de 10 minutos, visto que intervalos de menor duração englobavam poucas unidades produzidas quando o tempo de execução da operação fosse elevado. Quando a soma do tempo relativo à i -ésima unidade em um dado intervalo excedia 10 minutos, a unidade era contabilizada no intervalo seguinte. A Tabela 4 apresenta os dados de desempenho coletados na fabricação do *Calçado 24* e exemplifica a conversão dos mesmos na forma demandada pelas curvas de aprendizado selecionadas. O modelo *Calçado 24* foi escolhido aleatoriamente dentre os modelos analisados e utilizado para exemplificação dos procedimentos propostos. Os dados convertidos para os demais calçados analisados são apresentados no Apêndice 1.

A coleta limitava-se à medição do tempo demandado por par, não contemplando maiores avaliações acerca da qualidade dos calçados produzidos. Exemplares cujas características eram consideradas insatisfatórias eram separados da linha de produção e seu tempo de processamento era descartado pelo funcionário, ou seja, o calçado não era incluído na contagem das unidades produzidas no intervalo. A ocorrência de tais episódios durante a coleta de dados, entretanto, apresentou frequência extremamente baixa.

Tabela 4: Dados de desempenho coletados e convertidos para o modelo *Calçado 24*

UNIDADE	TEMPO(s)/ PAR	TEMPO ACUMULADO DE OPERAÇÃO (s)	TEMPO DE OPERAÇÃO (intervalos de 600s)	TEMPO DE OPERAÇÃO (intervalos de 10 min)	UNIDADES PRODUZIDAS/ 10 MINUTOS DE OPERAÇÃO
1	178	178	0 - 600	0 - 10	3
2	173	351			
3	203	554			
4	209	763	601 - 1200	10 - 20	3
5	202	965			
6	169	1134			
7	138	1272	1201 - 1800	20 - 30	5
8	130	1402			
9	116	1518			
10	116	1634			
11	105	1739			
12	116	1855	1801 - 2400	30 - 40	6
13	111	1966			
14	93	2059			
15	102	2161			
16	124	2285			
17	111	2396			
18	105	2501	2401 - 3000	40 - 50	6
19	96	2597			
20	97	2694			
21	106	2800			
22	93	2893			
23	102	2995			
24	91	3086			
25	95	3181	3001 - 3600	50 - 60	6
26	103	3284			
27	89	3373			
28	80	3453			
29	99	3552			
30	89	3641	3601 - 4200	60 - 70	7
31	93	3734			
32	86	3820			
33	84	3904			
34	107	4011			
35	82	4093			
36	98	4191	4201 - 4800	70 - 80	6
37	105	4296			
38	121	4417			
39	90	4507			
40	92	4599			
41	88	4687			
42	87	4774			
43	86	4860	4801 - 5400	80 - 90	7
44	87	4947			
45	79	5026			
46	83	5109			
47	85	5194			
48	86	5280			
49	100	5380			

Tabela 4: Dados de desempenho coletados e convertidos para o modelo *Calçado 24*
(continuação)

UNIDADE	TEMPO(s)/ PAR	TEMPO ACUMULADO DE OPERAÇÃO (s)	TEMPO DE OPERAÇÃO (intervalos de 600s)	TEMPO DE OPERAÇÃO (intervalos de 10 min)	UNIDADES PRODUZIDAS/ 10 MINUTOS DE OPERAÇÃO
50	98	5478	5401 - 6000	90 - 100	7
51	74	5552			
52	90	5642			
53	106	5748			
54	89	5837			
55	77	5914			
56	86	6000			
57	102	6102	6001 - 6600	100 - 110	6
58	92	6194			
59	97	6291			
60	95	6386			
61	101	6487			
62	81	6568			
63	91	6659	6601 - 7200	110 - 120	7
64	86	6745			
65	84	6829			
66	76	6905			
67	74	6979			
68	89	7068			
69	87	7155			
70	77	7232	7201 - 7800	120 - 130	8
71	74	7306			
72	69	7375			
73	70	7445			
74	90	7535			
75	81	7616			
76	77	7693			
77	79	7772			
78	90	7862	7801 - 8400	130 - 140	8
79	106	7968			
80	80	8048			
81	68	8116			
82	70	8186			
83	68	8254			
84	70	8324			
85	68	8392			
86	68	8460	8401 - 9000	140 - 150	9
87	69	8529			
88	74	8603			
89	63	8666			
90	76	8742			
91	62	8804			
92	61	8865			
93	64	8929			
94	63	8992			

O número de trocas de calçados verificado no período de coleta possibilitou a realização de todos os cruzamentos possíveis entre as famílias de modelos e as equipes de trabalhadores. Em média, cada equipe atuou em 2 modelos pertencentes a mesma família, o que permitiu a estimativa do erro experimental.

Os dados de desempenho dos cruzamentos entre as equipes e famílias de calçados foram modelados através de curvas de aprendizado descritas na literatura.

4.4 MODELAGEM DOS DADOS DE DESEMPENHO OBTIDOS NOS CRUZAMENTOS ATRAVÉS DE MODELOS DE CURVAS DE APRENDIZADO APRESENTADOS NA LITERATURA

Os dados de desempenho coletados foram modelados pelas equações (13), (14) e (16), através de regressão não linear utilizando o *software* SPSS v. 8.0. Os modelos hiperbólico e exponencial apresentaram convergência em todos os 20 casos analisados, mediante ajustes nos valores iniciais dos parâmetros no *software*. O modelo de tempo constante apresentou divergência em um episódio (*Calçado* 16). Os parâmetros gerados pelas regressões são apresentados na Tabela 5.

Tabela 5: Parâmetros gerados pelas curvas de aprendizado avaliadas

FAMÍLIA	CALÇADO	HIPERBÓLICO 3-PARÂMETROS			EXPONENCIAL 3-PARÂMETROS			TEMPO CONSTANTE		
		<i>k</i>	<i>p</i>	<i>r</i>	<i>k</i>	<i>p</i>	<i>r</i>	<i>y_c</i>	<i>y_f</i>	τ
FÁCIL (1)	<i>Calçado</i> 11	11,4	72,5	147	11,5	118	281	3,9	7,6	282
	<i>Calçado</i> 12	12,3	88	145	9,3	101	144	4,7	4,6	144
	<i>Calçado</i> 13	8,1	105	167	7,2	169	281	3,2	3,9	281
	<i>Calçado</i> 14	12,1	54,5	156	10,1	77,8	195	3,3	6,8	195
	<i>Calçado</i> 15	18,9	29	44	17	58,8	88,1	8,3	8,7	88,1
	<i>Calçado</i> 16	18,7	8,2	10,5	16,8	17,8	22,7	não convergiu		
	<i>Calçado</i> 17	6,4	94,8	123	5,1	115	142	2,8	2,3	142
MÉDIO (2)	<i>Calçado</i> 18	14,7	13	71,8	10,5	19,9	60,6	2,3	8,2	60,6
	<i>Calçado</i> 19	15,1	5,1	42,6	11,5	7,6	41,6	1,9	9,5	41,6
	<i>Calçado</i> 20	18,7	29,5	26,3	16,4	49,3	51	10,2	6,2	51
	<i>Calçado</i> 21	7,1	20,4	59,6	6,7	58,2	135	2,4	4,4	135
	<i>Calçado</i> 22	19,7	8,4	80	15,3	13,9	82,9	2,4	13	82,9
	<i>Calçado</i> 23	43	24,6	30,9	37,3	40,6	53	19,9	17,3	53,1
	<i>Calçado</i> 24	10,2	7,5	45,1	8,5	17,2	61,2	2,1	6,4	61,2
DIFÍCIL (3)	<i>Calçado</i> 25	9,8	77,9	68,7	9,1	161	180	5,4	3,7	180
	<i>Calçado</i> 26	4,5	19,2	64,9	4	50,2	122	1,3	2,6	122
	<i>Calçado</i> 27	17,6	22,9	36,8	14,8	36,1	55,1	7,1	7,7	55,1
	<i>Calçado</i> 28	11,1	37,1	221	7,3	38,5	158	1,6	5,8	158
	<i>Calçado</i> 29	27,1	29,3	19,3	24,4	53,2	46,2	16,7	7,7	46,3
	<i>Calçado</i> 30	8,8	36	52	7,8	75,9	105	4	3,8	105

A interpretação dos parâmetros gerados pode ser feita da seguinte forma (utilizando os resultados do modelo hiperbólico para o *Calçado* 24 como exemplo): (i) $k = 10,2$ - o desempenho máximo atingido pelo trabalhador quando seu aprendizado for integral será de 10,2 unidades produzidas a cada 10 minutos de operação; (ii) $p = 7,5$ - o trabalhador monitorado possui uma experiência prévia na execução dessa operação equivalente a 7,5 minutos de operação; e (iii) $r = 45,1$ - o trabalhador necessita de aproximadamente 45 minutos

de operação para atingir metade do desempenho máximo a ser alcançado, equivalente a 5,1 unidades produzidas a cada 10 minutos de operação.

A Figura 16 apresenta as 3 curvas geradas pelos modelos avaliados para o *Calçado 24*. A análise visual revela grande similaridade nos perfis formados a partir dos modelos para um tempo de operação de 150 minutos. O perfil designado por *experimental* corresponde aos dados brutos.

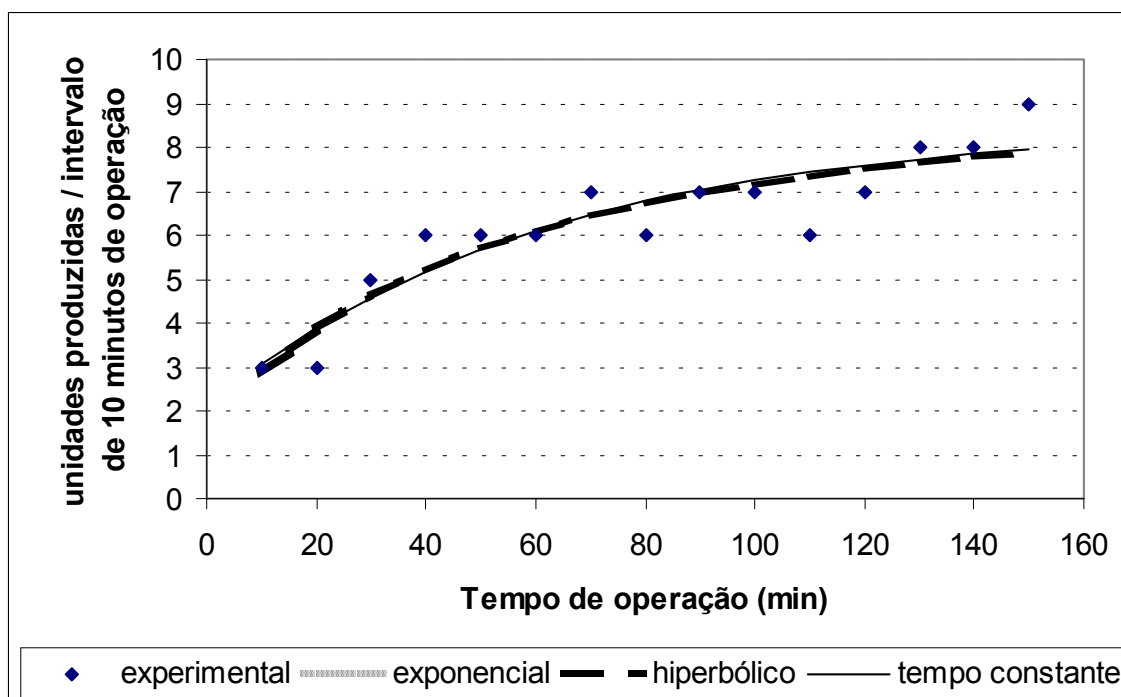


Figura 16: Perfis de aprendizado descritos pelos três modelos de curvas na produção do *Calçado 24*

A análise dos critérios de aderência - apresentados na seção 3.4 - mostrou que o modelo hiperbólico resultou em um desempenho superior aos modelos exponencial e de tempo constante nas modelagens realizadas. Os critérios avaliados são descritos nos itens seguintes e seus resultados apresentados na Tabela 7.

- (i) A equação hiperbólica resultou na menor média da soma dos quadrados dos erros (SQE) dentre os modelos de curvas de aprendizado avaliados, seguida pelos modelos exponencial e de tempo constante.

- (ii) Os coeficientes de determinação gerados pelas modelagens apresentaram valores muito próximos, significando uma aderência praticamente idêntica das curvas aos dados de desempenho.
- (iii) O modelo hiperbólico apresentou maior capacidade preditiva em uma amostra de validação, quando comparado aos demais modelos avaliados. Amostras de validação foram coletadas para modelos de calçados cujo período de produção fosse igual ou superior a dois dias. Tais amostras seriam características de equipes de trabalhadores onde se observou convergência no processo de aprendizado (ou seja, o desempenho medido convergiu para um valor estacionário). Abaixo é exemplificado o procedimento de determinação da capacidade preditiva dos modelos obtidos para o *Calçado 24*.

A amostra de validação para o *Calçado 24* foi realizada no final do 3º dia de produção, o que corresponde a aproximadamente 1500 minutos de operação do trabalhador na operação analisada (1 dia de trabalho na empresa analisada equivale a 528 minutos). A coleta seguiu o procedimento descrito na seção 3.3, sendo os dados de desempenho coletados na forma de tempo/par e convertidos a unidades produzidas por tempo de operação. A Tabela 6 apresenta os valores de produção previstos pelos 3 modelos analisados e os valores reais coletados na amostra de validação para intervalos de operação que vão de 1500 a 1550 minutos (sendo 50 minutos a duração aproximada da coleta). Os desvios calculados para os demais calçados analisados são apresentados na Tabela 7 (a ausência de valores de desvio, como, por exemplo, nos *Calçados 14* e *21*, corresponde a modelos com corridas de produção inferiores a dois dias).

Tabela 6: Desvios das estimativas geradas pelos 3 modelos de curvas para o *Calçado 24*

INTERVALO DE OPERAÇÃO (min)	PRODUÇÃO REAL (pares)	PRODUÇÃO PREVISTA PELO MODELO (pares):		
		HIPERBÓLICO 3-PARÂMETROS	EXPONENCIAL 3-PARÂMETROS	TEMPO CONSTANTE
1500 - 1510	10	9,9	8,5	8,5
1510 - 1520	10	9,9	8,5	8,5
1520 - 1530	10	9,9	8,5	8,5
1530 - 1540	11	9,9	8,5	8,5
1540 - 1550	10	9,9	8,5	8,5
TOTAL (pares)	51	49,5	42,5	42,5
DESVIO	-	-3%	-17%	-17%

Tabela 7: Resumo dos erros (SQE), coeficientes de determinação (R^2) e desvios resultantes das modelagens

FAMÍLIA	CALÇADO	HIPERBOLICO 3-PARÂMETROS			EXPONENCIAL 3-PARÂMETROS			TEMPO CONSTANTE		
		SQE	R^2	DESVIO	SQE	R^2	DESVIO	SQE	R^2	DESVIO
FÁCIL (1)	Calçado 11	4,4	0,6	8%	4,4	0,6	19%	4,4	0,6	19%
	Calçado 12	2,77	0,76	5%	2,75	0,76	-16%	2,75	0,76	-16%
	Calçado 13	4,9	0,64	-5%	4,9	0,64	-13%	4,9	0,64	-12%
	Calçado 14	8,1	0,69	-	8,1	0,69	-	8,1	0,69	-
	Calçado 15	10,7	0,77	3%	10,9	0,77	-6%	10,9	0,77	-6%
	Calçado 16	2,53	0,87	3%	2,38	0,87	-7%	não convergiu		
	Calçado 17	2,47	0,49	22%	2,47	0,5	2%	2,47	0,5	2%
MÉDIO (2)	Calçado 18	6,4	0,82	22%	6,3	0,82	-5%	6,3	0,82	-5%
	Calçado 19	4	0,91	23%	3,8	0,91	-4%	3,8	0,91	-5%
	Calçado 20	2,8	0,87	-6%	2,8	0,87	-16%	2,8	0,87	-16%
	Calçado 21	8,18	0,63	-	8,35	0,63	-	8,35	0,63	-
	Calçado 22	5,3	0,9	11%	5,4	0,9	-4%	5,4	0,9	-4%
	Calçado 23	20,7	0,72	-	20,8	0,72	-	20,8	0,72	-
	Calçado 24	5,9	0,85	-3%	6,3	0,84	-17%	6,3	0,84	-17%
DIFÍCIL (3)	Calçado 25	5,0	0,63	-9%	5,1	0,63	-12%	5,1	0,63	-12%
	Calçado 26	3,3	0,7	-18%	3,5	0,69	-24%	3,5	0,69	-26%
	Calçado 27	5,5	0,8	-	5,5	0,8	-	5,5	0,8	-
	Calçado 28	4,38	0,84	-5%	4,32	0,84	-30%	4,32	0,84	-30%
	Calçado 29	0,58	0,93	-	0,6	0,93	-	0,6	0,93	-
	Calçado 30	4,45	0,74	-	5,49	0,76	-	5,49	0,76	-
	MÉDIA	5,62	0,76	10,7%	5,71	0,76	12,1%	5,89	0,75	12,7%

O modelo hiperbólico apresentou os menores desvios em 10 dos 14 calçados em que foi efetuada a segunda etapa de coleta. Verificou-se que os valores de desempenho final (k) previstos por esse modelo são superiores aos valores estimados pelos demais. Essa constatação já havia sido feita por Mazur e Hastie (1978) com relação às equações hiperbólica e exponencial, o que pode ser estendido para o modelo de tempo constante em relação ao hiperbólico. De tal forma, por estimar valores de desempenho final mais elevados, a equação hiperbólica demanda mais tempo de operação para convergir ao valor limite k , quando comparada às demais equações analisadas.

Os parâmetros e desvios gerados pelo modelo de tempo constante apresentam grande similaridade com os apresentados pelo modelo exponencial. Esse resultado pode ser decorrente da semelhança entre as estruturas das equações.

A análise dos desvios e erros quadrados gerados pelas curvas de aprendizado apontou o modelo hiperbólico como o mais adequado para a caracterização das equipes de trabalhadores avaliadas. Seus parâmetros serão utilizados nas etapas seguintes de análise.

4.5 ANÁLISE DOS PARÂMETROS GERADOS PELA CURVA DE APRENDIZADO SELECIONADA

Os parâmetros gerados pela equação hiperbólica foram analisados através de dois métodos distintos: análise do parâmetro r_{ij} (regressão linear múltipla) e análise das curvas associadas aos modelos selecionados para cada tipo de calçado (mais especificamente, analisando as áreas geradas pelas curvas). A primeira forma é indicada para análises em corridas de produção de curta duração e a segunda pode ser utilizada em corridas de durações distintas.

4.5.1 Análise de Regressão sobre o Parâmetro de Taxa de Aprendizado (r) resultante da modelagem

As variáveis independentes consideradas na análise de regressão representam as famílias e as equipes de produtos analisadas. As 3 famílias na Tabela 7 foram assim codificadas: *Difícil* = 3, *Média* = 2 e *Fácil* = 1, sendo os valores atribuídos de acordo com a complexidade da família em questão. A numeração adotada para a identificação das 3 equipes baseou-se na média de idade dos componente de cada equipe monitorada (dados fornecidos pela empresa), sendo que ao maior valor de média foi atribuído o maior valor de escala. A Tabela 8 apresenta a escala gerada para as equipes.

Tabela 8: Valores de escala atribuídos às equipes monitoradas

EQUIPE	IDADE MÉDIA	X_1
<i>Equipe 1</i>	35	1
<i>Equipe 2</i>	37	2
<i>Equipe 3</i>	40	3

As escalas codificadas adotadas para as equipes (X_1) e para as famílias (X_2), bem como os valores de r_{ij} a serem utilizados no procedimento de regressão, são apresentados na Tabela 9. A variável X_1X_2 (interação equipe-família) é obtida através da multiplicação das variáveis X_1 e X_2 .

Tabela 9: Escalas codificadas e parâmetros r_{ij} obtidos através das modelagens por curvas de aprendizado

CALÇADO	r_{ij} modelado	TRABALHADORES		PRODUTOS	
		EQUIPE	X_1	FAMÍLIA	X_2
Calçado 11	147	Equipe 1	1	FÁCIL	1
Calçado 12	145	Equipe 1	1	FÁCIL	1
Calçado 13	167	Equipe 2	2	FÁCIL	1
Calçado 14	156	Equipe 2	2	FÁCIL	1
Calçado 15	44	Equipe 2	2	FÁCIL	1
Calçado 16	10,5	Equipe 3	3	FÁCIL	1
Calçado 17	128	Equipe 3	3	FÁCIL	1
Calçado 18	71,8	Equipe 1	1	MÉDIA	2
Calçado 19	42,6	Equipe 1	1	MÉDIA	2
Calçado 20	26,3	Equipe 1	1	MÉDIA	2
Calçado 21	59,6	Equipe 2	2	MÉDIA	2
Calçado 22	80	Equipe 2	2	MÉDIA	2
Calçado 23	30,9	Equipe 3	3	MÉDIA	2
Calçado 24	45,1	Equipe 3	3	MÉDIA	2
Calçado 25	68,7	Equipe 1	1	DIFÍCIL	3
Calçado 26	64,9	Equipe 2	2	DIFÍCIL	3
Calçado 27	36,8	Equipe 2	2	DIFÍCIL	3
Calçado 28	221	Equipe 3	3	DIFÍCIL	3
Calçado 29	19,3	Equipe 3	3	DIFÍCIL	3
Calçado 30	52	Equipe 3	3	DIFÍCIL	3

As constantes b_0 , b_1 , b_2 e b_3 da equação (29) foram estimadas com o auxílio do *software* SPSS v.8.0, através da opção de regressão linear. O coeficiente de determinação (R^2) obtido foi de 0,21, indicando uma baixa aderência do modelo de regressão aos dados analisados. O modelo gerado é apresentado na equação (30).

$$r_{ij} = 266,5 - 70,2X_1 - 93,5X_2 + 34,3X_1X_2 \quad (30)$$

A análise da grandeza das constantes mostra que alterações na variável X_2 acarretam as maiores diminuições no valor de r_{ij} , revelando que as maiores variações na taxa de aprendizado do trabalhador são decorrentes da modificação da família em operação. A variável X_1 opera no mesmo sentido, porém sua magnitude é menor do que X_2 . A variável de interação (X_1X_2) atua de forma a aumentar o valor da taxa de aprendizado.

A significância das variáveis independentes é apresentada na Tabela 10. Considerando um grau de confiança de 10%, apenas X_2 é significativa, apesar de as significâncias de X_1 e X_1X_2 apresentarem valores bastante próximos ao limite de corte (0,10). Esse resultado

demonstra que a família de calçados (X_2) é responsável pelas maiores variações sobre o parâmetro de taxa de aprendizado. A alteração de equipe (X_1) impacta em menores variações de r_{ij} , o que pode ser justificado pelos padrões de desempenho semelhantes das equipes. A interação, a exemplo da equipe, também não é responsável por variações acentuadas em r_{ij} .

Tabela 10: Significâncias das variáveis independentes do modelo de regressão obtido

VARIÁVEL	SIGNIFICÂNCIA
Constante	0,014
X_1	0,129
X_2	0,068
X_1X_2	0,119

Os valores de r_{ij} gerados pelo modelo de regressão para as equipes e famílias analisadas são apresentados na Tabela 11. Os desvios relativos entre os valores modelados pela curva de aprendizado e os valores gerados pelo modelo de regressão são calculados utilizando-se o parâmetro r_{ij} modelado médio, obtido através da média dos parâmetros r_{ij} para cruzamentos repetidos de uma equipe i com uma família j de produtos.

A análise dos valores de r_{ij} gerados pelo modelo de regressão permite apontar a equipe mais habilitada à execução das operações relativas a cada família de produtos. Os valores mais baixos de r_{ij} devem ser priorizados, visto que indicam a necessidade de menor tempo de operação para a obtenção de determinado patamar de desempenho. Por exemplo, a *Equipe 3* é a mais apta à execução das operações pertencentes à família 1 (*Fácil*), visto que o seu parâmetro de taxa de aprendizado ($r_{31} = 65,2$) é inferior aos parâmetros apresentados pelas *Equipes 1* e 2 ($r_{11} = 137$ e $r_{21} = 101$, respectivamente).

Dada a grande variabilidade de r_{ij} modelado dentro do mesmo cruzamento, realizou-se a ponderação dos coeficientes da equação (30), utilizando-se como peso o inverso da variância dos valores de r_{ij} para cada cruzamento (MONTGOMERY; PECK, 1992). O procedimento foi realizado através do *software* SPSS v.8.0, sendo os valores obtidos apresentados no Apêndice 2. A ponderação apresentou melhoria no desvio médio de 32% para 29%, mas não implicou em modificações nas significâncias das variáveis em relação à primeira regressão realizada, fazendo com que os resultados da ponderação fossem descartados.

Tabela 11: Comparação entre os valores de r_{ij} modelados pela curva de aprendizado e os estimados pelo modelo de regressão

Equipe (X_1)	Família (X_2)	r_{ij} modelado	r_{ij} modelado médio	r_{ij} estimado (regressão)	Desvio relativo
1	1	147	146	137	-6%
1	1	145			
2	1	167	122	101	-17%
2	1	156			
2	1	44			
3	1	10,5	66,8	65,2	-2%
3	1	123			
1	2	71,8	46,9	77,8	66%
1	2	42,6			
1	2	26,3			
2	2	59,6	69,8	76,2	9%
2	2	80			
3	2	30,9	38	74,6	96%
3	2	45,1			
1	3	68,7	68,7	18,6	-73%
2	3	64,9	50,9	51,3	1%
2	3	36,8			
3	3	220	97,1	84	-14%
3	3	19,3			
3	3	52			
Desvio médio absoluto					32%

A análise realizada neste estudo de caso poderia ter sido executada através da avaliação direta dos parâmetros r_{ij} originados da modelagem por curva de aprendizado, visto que o número de famílias e equipes é reduzido (3 equipes e 3 famílias). A execução de análise similar em processos constituídos por um número elevado de variáveis, entretanto, pode inviabilizar a realização de todos os cruzamentos possíveis, tornando proveitosa a utilização de um modelo de regressão semelhante ao obtido. Um exemplo é desenvolvido utilizando-se os dados disponíveis neste estudo de caso (apresentados na Tabela 11). Os valores de r_{ij} relativos aos cruzamentos da *Equipe 2* com a família de produtos *Média* ($r_{22} = 59,6$ e $r_{22} = 80$) são eliminados, simulando um episódio em que não foi possível coletar dados de desempenho relativos a esse cruzamento. Os novos valores das constantes do modelo de regressão, calculados sem os valores de r_{22} , são apresentados na equação (31).

$$r_{ij} = 266,4 - 69,9X_1 - 93X_2 + 34,1X_1X_2 \quad (31)$$

A substituição de $X_1 = 2$, $X_2 = 2$ e $X_1X_2 = 4$ (variáveis de regressão relativas ao cruzamento omitido) na equação (31) resulta em $r_{22} = 77$, representando um desvio de 10% em relação ao valor modelado pela curva de aprendizado ($r_{22} = 69,8$). De tal forma, verifica-se que o modelo de regressão gera uma boa estimativa de r_{ij} para um cruzamento que, na prática, não foi realizado.

O método proposto de análise isolada de r , apesar de gerar bons resultados, é limitado para aplicações em corridas curtas de produção. A análise do conjunto de parâmetros gerados pela modelagem, por sua vez, pode conduzir a avaliações mais completas e aplicáveis a tempos distintos de operação, conforme apresentado a seguir.

4.5.2 Análise das Curvas de Aprendizado construídas a partir dos Parâmetros gerados pela Modelagem

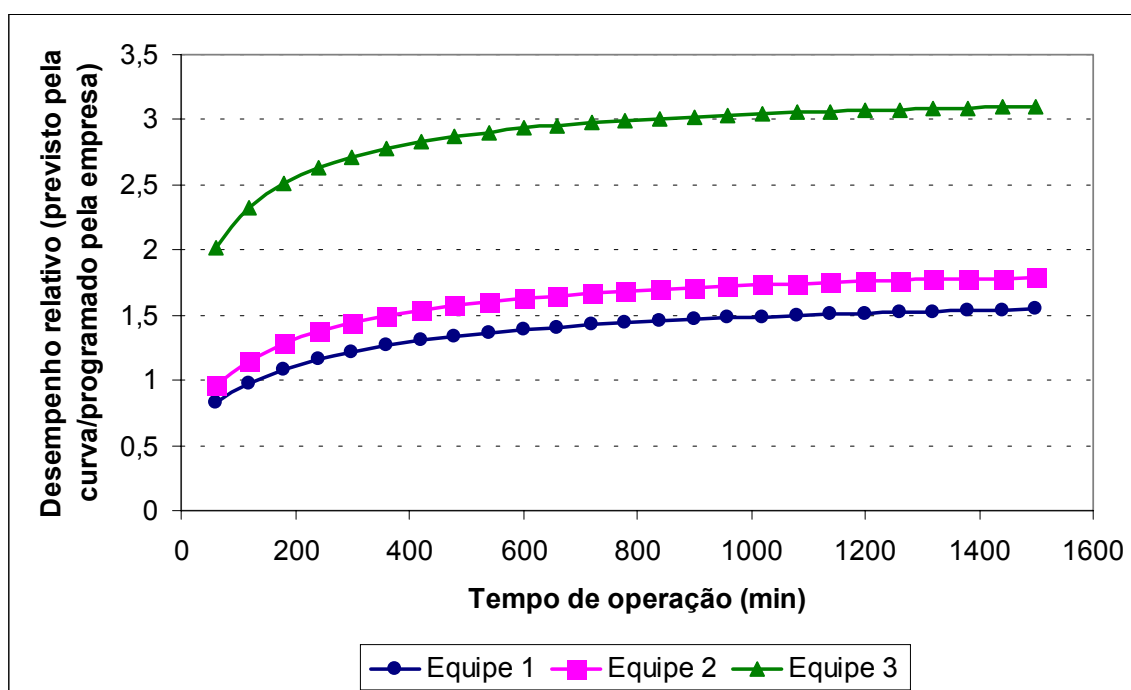
Os parâmetros k_{ij} , p_{ij} e r_{ij} gerados pela curva hiperbólica para os *Calçados* 11 a 30 são apresentados na Tabela 5. Calculou-se a média dos parâmetros p_{ij} e r_{ij} , referentes aos cruzamentos repetidos de uma equipe i com uma família j de produtos, gerando os parâmetros médios \bar{p}_{ij} e \bar{r}_{ij} .

O parâmetro k_{ij} foi dividido pela produção programada pela empresa (em número de unidades a serem produzidas em 10 minutos de operação, conforme apresentado na Tabela 12), gerando uma escala relativa de produção (k_{ij}^r). Essa conversão tem por objetivo eliminar diferenças significativas de escala nos tempos de execução das operações analisadas. Casos em que a operação analisada fosse composta por mais de um trabalhador tinham sua demanda convertida em unidades produzidas em 10 minutos por trabalhador. As repetições de cruzamentos demandavam a determinação de \bar{k}_{ij}^r , realizado de acordo com o exemplo apresentado na seção 3.5.2. A Tabela 12 exemplifica a obtenção dos parâmetros \bar{k}_{12}^r , \bar{p}_{12} e \bar{r}_{12} gerados a partir dos dados de 3 calçados pertencentes à família *Média* ($j = 2$) e elaborados pela *Equipe 1* ($i = 1$). Os parâmetros médios foram utilizados para a construção de curvas relativas a cada cruzamento modelado.

Tabela 12: Procedimento de obtenção dos parâmetros médios para 3 modelos de calçados

Calçado	Nº de postos/esteira	Demanda (pares/dia)	Demanda (pares/10 min de operação)	k_{ij} (pares/10 minutos de operação)	$k^{r_{ij}}$	p_{ij} (minutos)	r_{ij} (minutos)
Calçado 18	2	1150	11	14,70	1,35	13	71,8
Calçado 19	2	520	5	15,10	3,07	5,1	42,6
Calçado 20	1	700	13	18,70	1,41	29,5	26,3
Parâmetros médios					1,94	15,9	46,9

As curvas geradas foram organizadas em gráficos de acordo com a família de produtos. De tal forma, foram construídos 3 gráficos relativos às famílias *Fácil*, *Média* e *Difícil*, sendo cada gráfico composto por 3 curvas representativas do desempenho de cada equipe analisada. Os gráficos gerados para cada família, tendo as ordenadas expressas em escala relativa de produção, são apresentados nas Figuras 17, 18 e 19.

Figura 17: Perfis gerados na execução de calçados pertencentes à Família *Fácil*

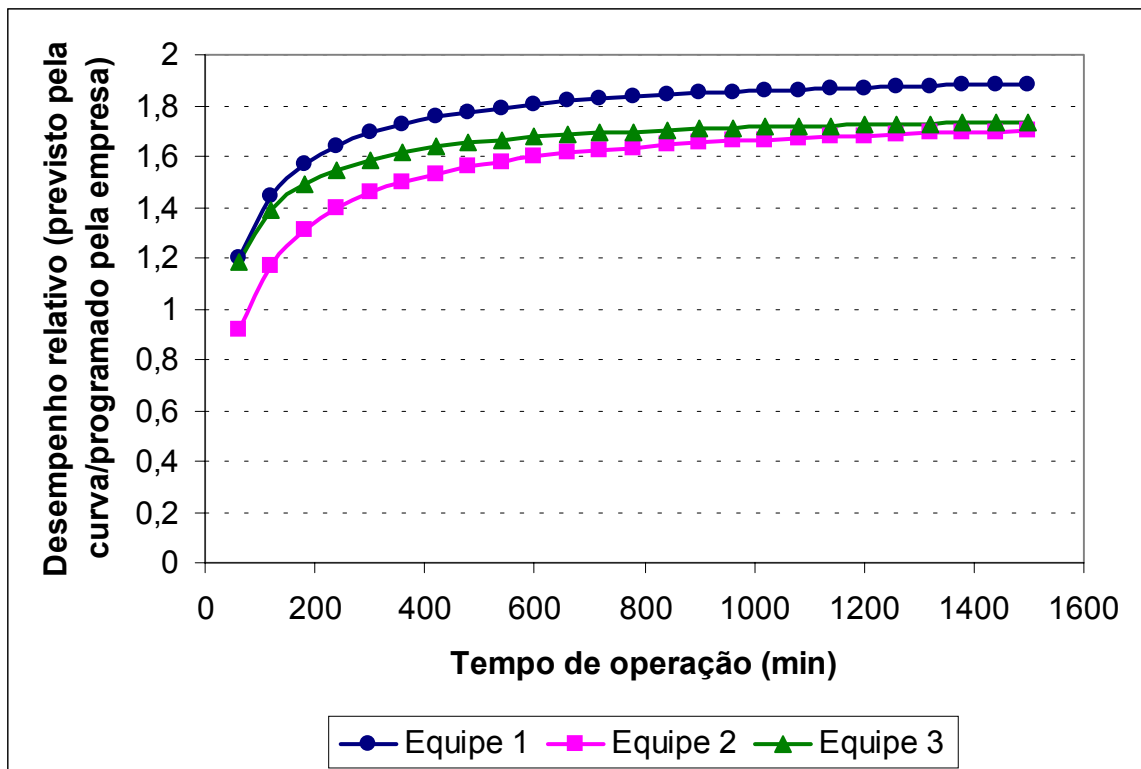


Figura 18: Perfis gerados na execução de calçados pertencentes à Família *Média*

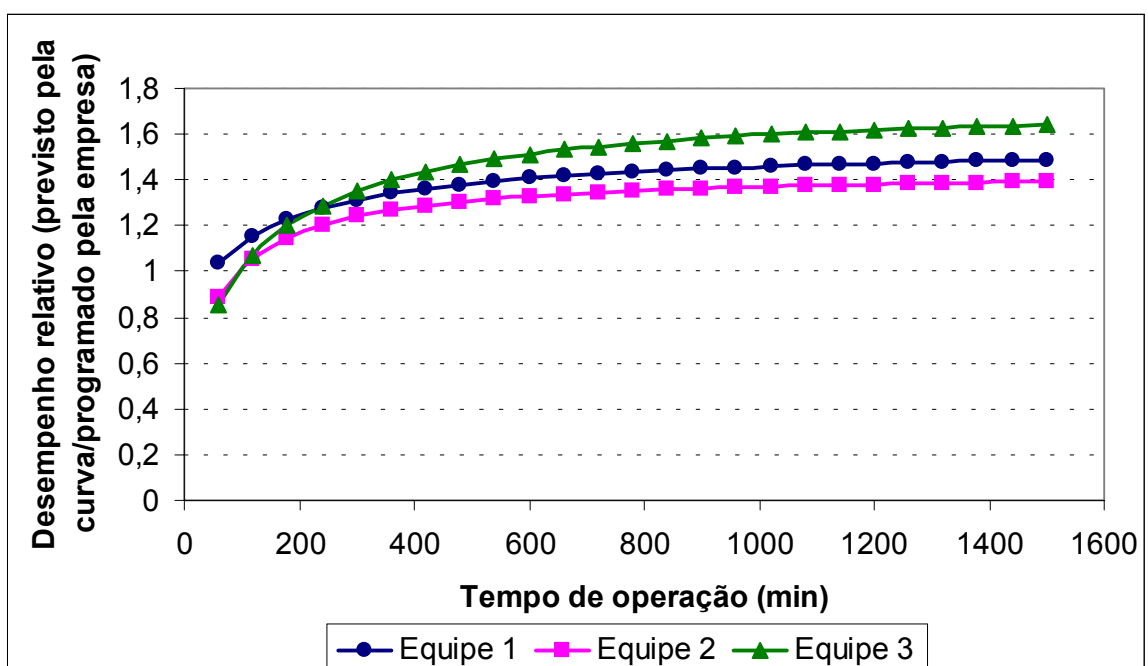


Figura 19: Perfis gerados na execução de calçados pertencentes à Família *Difícil*

A análise do aprendizado das equipes na execução das operações relativas a cada família foi feita através da avaliação da área sob as curvas de aprendizado geradas. A área foi calculada através da integração analítica da equação hiperbólica, cuja primitiva é apresentada na equação (32).

$$y = kx - kr \ln(x + p + r) \quad (32)$$

A integração foi realizada para intervalos de tempo de 60 minutos, sendo esse valor de tempo adequado frente à duração da maioria das corridas de produção analisadas. O limite superior de integração foi fixado de maneira independente para cada família analisada, buscando-se eliminar a possibilidade de cruzamento entre as curvas para horizontes longos de produção, o que poderia determinar uma nova equipe como a detentora do maior desempenho acumulado (maior área). Na Tabela 13 são apresentados os valores de área obtidos pela integração das curvas geradas pelas 3 equipes analisadas atuando em produtos da família *Difícil*. Os valores destacados em negrito apontam a equipe mais indicada para a execução das operações, de acordo com a duração da corrida de produção. As áreas para as demais famílias de calçados (*Média e Fácil*) são apresentadas no Apêndice 3.

Tabela 13: Áreas geradas pelas 3 equipes na execução das operações relativas à Família

Difícil

Tempo de operação (min)	Área sob a curva			Tempo de operação (min)	Área sob a curva		
	Equipe 1	Equipe 2	Equipe 3		Equipe 1	Equipe 2	Equipe 3
60	57	42	41	3060	4417	4125	4801
120	122	101	99	3120	4508	4210	4902
180	194	167	168	3180	4600	4295	5004
240	269	238	243	3240	4691	4380	5106
300	347	311	322	3300	4782	4465	5208
360	426	387	404	3360	4873	4550	5309
420	507	463	490	3420	4964	4635	5411
480	590	541	577	3480	5056	4720	5513
540	673	620	666	3540	5147	4805	5615
600	757	700	756	3600	5238	4890	5717
660	842	780	847	3660	5330	4976	5819
720	927	860	940	3720	5421	5061	5921
780	1013	941	1033	3780	5512	5146	6023
840	1100	1022	1127	3840	5604	5231	6126
900	1186	1104	1221	3900	5695	5316	6228
960	1274	1186	1317	3960	5787	5401	6330
1020	1361	1268	1412	4020	5878	5487	6432
1080	1449	1350	1508	4080	5970	5572	6535
1140	1537	1433	1605	4140	6061	5657	6637
1200	1625	1516	1702	4200	6153	5742	6739
1260	1713	1599	1799	4260	6245	5828	6842
1320	1802	1682	1897	4320	6336	5913	6944
1380	1891	1765	1995	4380	6428	5998	7047
1440	1980	1848	2093	4440	6520	6084	7149
1500	2069	1932	2191	4500	6611	6169	7252
1560	2158	2015	2290	4560	6703	6254	7354
1620	2247	2099	2389	4620	6795	6340	7457
1680	2337	2183	2488	4680	6886	6425	7560
1740	2427	2267	2587	4740	6978	6510	7662
1800	2516	2351	2686	4800	7070	6596	7765
1860	2606	2435	2786	4860	7162	6681	7868
1920	2696	2519	2885	4920	7253	6767	7970
1980	2786	2603	2985	4980	7345	6852	8073
2040	2876	2687	3085	5040	7437	6938	8176
2100	2966	2771	3185	5100	7529	7023	8279
2160	3057	2856	3286	5160	7621	7108	8382
2220	3147	2940	3386	5220	7713	7194	8484
2280	3237	3024	3487	5280	7804	7279	8587
2340	3328	3109	3587	5340	7896	7365	8690
2400	3418	3193	3688	5400	7988	7450	8793
2460	3509	3278	3789	5460	8080	7536	8896
2520	3599	3362	3890	5520	8172	7621	8999
2580	3690	3447	3990	5580	8264	7707	9102
2640	3781	3532	4092	5640	8356	7792	9205
2700	3872	3616	4193	5700	8448	7878	9308
2760	3962	3701	4294	5760	8540	7964	9411
2820	4053	3786	4395	5820	8632	8049	9514
2880	4144	3871	4496	5880	8724	8135	9617
2940	4235	3956	4598	5940	8816	8220	9720
3000	4326	4040	4699	6000	8908	8306	9823

A análise das áreas geradas sob as curvas permite a alocação das Famílias às equipes mais habilitadas à execução das operações, conforme descrito na próxima seção.

4.6 ALOCAÇÃO DAS FAMÍLIAS DE PRODUTOS ÀS EQUIPES DE TRABALHADORES

Conforme exposto, dois métodos podem ser utilizados para alocação das famílias de produtos às equipes de trabalhadores: análise isolada do parâmetro r_{ij} ou integração das curvas de aprendizado. O primeiro método permite alocações seguras para corridas de produção de curta duração. Nesse contexto de produção, de acordo com os valores de r_{ij} estimados pela regressão e apresentados na Tabela 11, a *Equipe 3* é a mais adequada para a execução dos produtos pertencentes às famílias *Fácil* e *Média*, visto que os valores de r_{ij} estimados para essa equipe são inferiores aos gerados pelas demais. A *Equipe 1* credencia-se como a mais apta à realização das operações relativas à família *Difícil*.

Esse método, entretanto, não pode ser estendido para corridas longas, visto que equipes que apresentam melhores taxas de aprendizado inicial podem não atingir um desempenho final proporcional e serem superadas por equipes caracterizadas por aprendizado lento e desempenho final elevado (ver Figura 19). O método baseado na integração das curvas de aprendizado, por sua vez, pode ser utilizado para analisar o desempenho de equipes atuando em corridas de durações distintas, visto que os perfis gerados carregam a influência dos parâmetros \bar{k}_{ij} , \bar{p}_{ij} e \bar{r}_{ij} .

Para os calçados analisados, as áreas geradas pela integração das curvas dos modelos pertencentes à família *Difícil* mostraram que a *Equipe 1* apresentou o maior aprendizado para operações cuja corrida de produção tem duração estimada inferior a 600 minutos. Para corridas de produção cuja duração estimada é superior a esse valor, a *Equipe 3* passa a ser a mais adequada. Corridas com duração próxima a 600 minutos podem ter seus produtos alocados às *Equipes 1* ou *3*, sem haver diferença significativa nos níveis de produção resultantes. A *Equipe 2* é a menos indicada para execução de operações relativas aos calçados pertencentes à família *Difícil*.

Os calçados classificados como *Médios* devem ser direcionados à *Equipe 1*, independentemente da duração estimada de processamento do lote. Essa equipe apresentou a maior área sob a curva de aprendizado para qualquer tempo de integração. A análise

complementar do gráfico desta família mostra que as curvas geradas pelas *Equipes* 2 e 3 são muito próximas, porém não atingirão o patamar de desempenho da *Equipe* 1. A *Equipe* 3 apresenta melhores resultados que a *Equipe* 2 para corridas de duração inferiores a 1000 minutos, havendo posteriormente uma equiparação dos desempenhos. Assim, a *Equipe* 3 é tida como a segunda alternativa para processamento de lotes de calçados *Médios*.

As curvas geradas na execução dos calçados classificados como *Fácil* apresentam os resultados mais contrastantes. A *Equipe* 3 atinge patamares de desempenho final muito superiores aos das *Equipes* 1 e 2, apresentando valores de área equivalentes ao dobro dos gerados pelas demais equipes.

De tal forma, as alocações sugeridas pelos dois métodos (regressão e integração) mostraram-se coincidentes em dois dos três casos analisados, apontando a *Equipe* 3 como a mais habilitada para a execução das operações relativas à família *Fácil* e a *Equipe* 1 para corridas curtas da família *Difícil*. As curvas geradas pelas *Equipes* 1 e 3 na execução da família mais complexa apresentaram um cruzamento decorridos 600 minutos de operação, significando que a primeira equipe apresentou aprendizado mais acentuado nas primeiras horas de atividade, mas foi superada pela *Equipe* 3 com o transcorrer do processo. Por conta deste cruzamento, confirma-se a abrangência de avaliação de cada método segundo a duração da corrida de produção: a regressão aponta a *Equipe* 1 como a que apresenta melhor aprendizado na partida do processo, mas não prevê a superação desse aprendizado pela *Equipe* 3 em corridas mais longas (situação prevista pelo método da integração).

Não houve concordância de alocação em relação à família *Média*, para a qual os métodos indicaram equipes distintas. Analisando o gráfico gerado para esse caso (ver Figura 18), verifica-se que as curvas apresentam comportamentos bastante próximos, sendo que essa similaridade não é captada pelo método de análise isolada de r_{ij} devido à baixa aderência obtida pela regressão ($R^2 = 0,21$). Nessa situação, o resultado gerado pelo método baseado na análise das áreas deve ser priorizado, fazendo com que os calçados inseridos na família *Média* sejam direcionados para a *Equipe* 1. O Quadro 6 apresenta o resumo das alocações das famílias às equipes sugeridas pelos dois métodos.

FAMÍLIA	MÉTODO DE ALOCAÇÃO	
	REGRESSÃO	INTEGRAÇÃO
<i>Fácil</i>	<i>Equipe 3</i>	<i>Equipe 3</i>
<i>Média</i>	<i>Equipe 3</i>	<i>Equipe 1</i>
<i>Difícil</i>	<i>Equipe 1</i>	$t_{\text{duração}} < 600 \text{ min}$ - <i>Equipe 1</i> $t_{\text{duração}} > 600 \text{ min}$ - <i>Equipe 3</i>

Quadro 6: Resumo das alocações sugeridas pelos métodos

CAPÍTULO 5

5 CONCLUSÃO

A realização desta dissertação de mestrado permitiu a formulação de algumas conclusões a respeito da elaboração de uma metodologia de utilização de curvas de aprendizado para a alocação de produtos a equipes de trabalhadores, assim como sugestões para possíveis trabalhos futuros.

Essa dissertação teve como objetivo principal a apresentação de uma metodologia de utilização de curvas de aprendizado como balizadoras da alocação de famílias de produtos a equipes de trabalhadores. O método proposto é fundamentado na modelagem dos dados de desempenho de trabalhadores submetidos a alterações freqüentes nos modelos de produtos através de curvas de aprendizado. Para tanto, foi necessário um levantamento teórico detalhado a respeito dos modelos, aplicações e limitações das curvas de aprendizado.

O estudo também apresentou uma breve revisão sobre técnicas de clusterização. A formação de *clusters* foi utilizada para reduzir a quantidade de dados a serem coletados e analisados. Foi realizada ainda uma revisão sobre os fundamentos de regressão linear múltipla.

A metodologia proposta na dissertação foi ilustrada através de um estudo de caso, utilizando as curvas de aprendizado para a alocação de modelos de calçados a equipes de trabalhadores do setor de costura de uma empresa calçadista. A grande variedade de produtos, característica de sistemas com flexibilidade de catálogo, foi controlada através da formação de famílias de produtos com características similares, por intermédio de rotinas de clusterização.

Os dados de desempenho coletados foram utilizados para a avaliação de três modelos distintos de curvas de aprendizado (hiperbólico de 3 parâmetros, exponencial de 3 parâmetros e tempo constante), segundo critérios de aderência aos dados e de capacidade preditiva. Os modelos avaliados apresentaram níveis de aderência inferiores aos obtidos por Mazur e Hastie (1978) e Nembhard e Uzumeri (2001a). Tal discrepância pode ser associada às condições de realização dos experimentos, principalmente em relação ao método de coleta de dados e à natureza das operações avaliadas. A capacidade preditiva dos modelos, entretanto, apresentou resultados satisfatórios quando avaliada em uma amostra de validação. O modelo hiperbólico de 3 parâmetros apresentou os melhores resultados de adequação aos dados, sendo utilizado para as etapas seguintes propostas pela metodologia.

A interpretação dos parâmetros das curvas de aprendizado através de duas formas distintas (regressão e integração) permitiu a alocação de produtos a equipes de acordo com a duração da corrida de produção. A regressão mostrou-se adequada para a alocação de produtos a equipes em corridas de produção de curta duração, além de permitir a análise da influência de cada variável independente (equipe de trabalhadores, família de produto e interação equipe \times família) no processo de aprendizado dos trabalhadores. A integração, por sua vez, mostrou-se mais robusta que a regressão para fins de alocação, podendo ser utilizada em corridas de durações distintas mediante a comparação das áreas geradas pelas curvas de aprendizado.

A metodologia mostrou-se eficiente para o direcionamento de modelos de calçados às equipes mais habilitadas à realização das operações, buscando a redução das perdas (baixos níveis de produção) verificadas nos primeiros itens produzidos. A análise dos parâmetros gerados pelas modelagens apontou a existência de perfis distintos de adequação das equipes aos diversos modelos de produtos, possibilitando a identificação da equipe mais habilitada à execução dos produtos de cada família. O estudo de caso revelou que as *Equipes 1 e 3* apresentaram melhor adaptação às famílias de produtos analisadas, devendo ser priorizadas na execução das operações demandadas.

O estudo aqui desenvolvido pode ser estendido para além dos limites desta dissertação de mestrado. Na seqüência são apresentadas sugestões de estudos futuros através da aplicação de curvas de aprendizado.

Os modelos de curvas de aprendizado abordados nessa metodologia utilizam somente a variável de produtividade para a mensuração do aprendizado do trabalhador. A utilização de

modelos de curvas de aprendizado que incorporem variáveis relativas à qualidade dos produtos fabricados constitui-se em assunto interessante para a realização de estudo futuro. A avaliação de uma variável de qualidade permitirá alocações de produtos a equipes baseadas em termos de produtividade e de adequação dos produtos aos preceitos de qualidade.

A metodologia proposta é baseada na coleta de dados de desempenho dos trabalhadores em uma única operação gargalo (em termos de aprendizado) dentro de cada equipe do setor analisado. A coleta de dados de um maior número de operações importantes da mesma equipe, sugestão para um estudo futuro, possibilitará verificar a existência de variabilidade nos perfis de aprendizado dos trabalhadores dentro de uma mesma equipe e conduzirá a alocações dos produtos de maneira mais precisa.

A análise da influência das características do produto que vinha sendo fabricado sobre a adaptação do trabalhador ao novo modelo que será produzido também se configura em uma extensão interessante para este trabalho.

Em determinados sistemas produtivos, equipes apresentam seus integrantes “engessados” na execução de uma operação específica, independente das alterações nos modelos de produtos demandados. Em um estudo futuro, as curvas de aprendizado podem ser utilizadas para otimizar a rotação de trabalhadores de uma mesma equipe de acordo com os modelos de produtos solicitados. Em uma segunda etapa, trabalhadores de várias equipes podem ser rotados entre as equipes obedecendo às características dos modelos de produtos demandados, buscando-se minimizar as perdas por troca de modelo e aumentar a flexibilidade dos recursos humanos.

REFERÊNCIAS

- ADLER, P. S.; CLARK, K. B. Behind the Learning Curve: A Sketch of the Learning Process. **Management Science**, v. 37, n. 3, p. 267-281, 1991.
- AGRELL, P. J.; BOGETOFT, P.; TIND, J. Incentive Plans for Productive Efficiency, Innovation and Learning. **International Journal of Production Economics**, v. 78, n. 1, p. 1-11, 2002.
- ANDERSON, J. R. Acquisition of Cognitive Skill. **Psychological Review**, v. 89, p. 369-406, 1982.
- ANDRADE, M. C.; PESSANHA FILHO, R. C.; ESPONZEL, A. M.; MAIA, L. O. A.; QASSIM, R. Y. Activity-Based Costing for Production Learning. **International Journal of Production Economics**, v.62, p.175-180, 1999.
- ARGOTE, L.; BECKMAN, S. L.; EPPLE, E. The Persistence and Transfer of Learning in Industrial Settings. **Management Science**, v. 36, n. 2, p. 140-154, 1990.
- BADIRU, A. B. Computational Survey of Univariate and Multivariate Learning Curve Models. **IEEE Transactions on Engineering Management**, v. 39, n. 2, p. 176-188, 1992.
- BAILEY, C. D.; McINTYRE, E. V. Using Parameter Prediction Models to Forecast Post-Interruption Learning. **IIE Transactions**, v. 35, p. 1077-1090, 2003.

BENCHEKROUN, T. H. Caso de uma Indústria Alimentar. In: Fórum Brasileiro de Ergonomia, Porto alegre, 2000.

BLANCETT, R. S. Learning from Productivity Learning Curves. **Research-Technology Management**, May-June 2002.

CHAMBERS, S.; JOHNSTON, R. Experience Curves in Services: Macro and Micro Level Approaches. **International Journal of Operations & Production Management**, v. 20, n. 7, p. 842-859, 2000.

CHATTERJEE, S.; PRICE, B. **Regression Analysis by Example** 2.ed. New York: John Wiley & Sons, Inc, 1991.

COSTA, A. B. **Estudo da Competitividade da Indústria Brasileira**. Ministério da Ciência e Tecnologia – MCT, Programa de Apoio ao Desenvolvimento Científico e Tecnológico - PADCT. Campinas, 1993.

COX, W. E. Product Life Cycles as Marketing Models. **Journal of Business** (Chicago), p. 375, October 1967.

DAR-EL, E. M.; RUBINOVITZ, J. Using Learning Theory in Assembly Lines for New Products. **International Journal of Production Economics**, v. 25, p. 103-109, 1991.

DE RON, A. J. Sustainable Production: the Ultimate Result of a Continuous Improvement. **International Journal of Production Economics**, v. 56-57, p. 99-110, 1998.

DRAPER, N.; SMITH, H. **Applied Regression Analysis**. 2.ed. New York: John Wiley & Sons, Inc, 1981.

EDEN, C.; WILLIAMS, T.; ACKERMANN, F. Dismantling the Learning Curve: the Role of Disruptions on the Planning of Development Projects. **International Journal of Project Management**, v. 16, n. 3, p. 131-138, 1998.

EYRING, J. D.; JOHNSON, D. S.; FRANCIS, D. J. A Cross-Level Units-of-Analysis Approach to Individual Differences in Skill Acquisition. **Journal of Applied Psychology**, v. 78, n. 5, p. 805-814, 1993.

FEUERSTEIN, M. **Workstyle: Definition, empirical support, and implications for prevention, evaluation, and rehabilitation of occupational upper-extremity disorders in Beyond Biomechanics: Psychosocial Aspects of Musculoskeletal Disorders in Office Work.** Londres: Taylor & Francis Ltd., 1996.

FINE, C. H. Quality Improvement and Learning in Productive Systems. **Management Science**, v. 10, p. 1301-1315, 1986.

FRANCESCHINI, F.; GALETTO, M. Asymptotic Defectiveness of Manufacturing Plants: an Estimate Based on Process Learning. **International Journal of Production Research**, v. 40, n. 3, p. 537-545, 2002.

GIL, A. C. **Como elaborar projetos de pesquisa.** 3.ed. São Paulo: Atlas, 1991.

GINZBURG, S.; DAR-EL, E. M. Skill Retention and Relearning – a Proposed Cyclical Model. **Journal of Workplace Learning**, v. 12, n. 8, p. 327-332, 2000.

GLOBERSON, S. The Deviation of Actual Performance Around Learning Curve Models. **International Journal of Production Research**, v. 22, n. 1, p. 51-62, 1984.

GLOBERSON, S.; GOLD, D. Statistical Attributes of the Power Learning Curve Model. **International Journal of Production Research**, v. 35, n. 3, p. 699-711, 1997.

GLOBERSON, S.; LEVIN, N. Incorporating Forgetting into Learning Curves. **International Journal of Production Management**, v. 7, p. 80-94, 1987.

GLOBERSON, S.; LEVIN, N.; SHTUB, A. The Impact of Breaks on Forgetting When Performing a Repetitive Task. **IIE Transactions**, December 1989.

GNANADESIKAN, R. **Methods for Statistical Data Analysis of Multivariate Observations.** 2.ed. New York: John Wiley & Sons, Inc., 1997.

HAIR, J. F. JR.; ANDERSON, R. E.; TATHAM, R. L.; BLACK, W. C. **Multivariate Data Analysis with Readings.** 4.ed. New Jersey: Prentice-Hall Inc., 1995.

HURLEY, J. W. When Are We Going to Change the Learning Curve Lecture? **Computers Operations Research**, v. 23, n. 5, p. 509-511, 1996.

JABER, M. Y.; BONNEY, M. Economic Lot Sizing with Learning and Continuous Time Discounting: Is it Significant? **International Journal of Production Economics**, v. 71, p. 135-143, 2001.

JABER, M. Y.; BONNEY, M. Production Breaks and the Learning Curve: the Forgetting Phenomenon. **Applied Mathematics Modelling**, v. 20, p. 162-169, 1996.

JABER, M. Y.; BONNEY, M. The Economic Manufacture/Order Quantity (EMQ/EOQ) and the Learning Curve: Past, Present, and Future. **International Journal of Production Economics**, v. 59, p. 93-102, 1999.

JACINTO, A. A. **Estudo da curva de aprendizagem:** em uma indústria exportadora de calçados. Lajeado: Univates – Centro Universitário, 2001. Monografia de Graduação em Administração com habilitação em Comércio Exterior.

JOBSON, J. D . **Applied Multivariate Data Analysis – Volume I:** Regression and Experimental Design. New York: Springer-Verlag, 1991.

JOBSON, J. D. **Applied Multivariate Data Analysis, Volume II:** Categorical and Multivariate Methods. New York: Springer-Verlag, 1992.

JOHNSON, R. A.; WICHERN, D. W. **Applied Multivariate Statistical Analysis**, 3.ed. [s.l]: Prentice-Hall International, Inc, 1992.

KANFER, R. Motivation and Individual Differences in Learning: an Integration of Developmental, Differential and Cognitive Perspectives. **Learning and Individual Differences**, v. 2, n. 2, p. 221-239, 1990.

KILBRIDGE, M. A Model for Industrial Learning Costs. **Management Science**, v. 8, n. 4, p. 516-527, 1962.

KOUBEK, R. J.; LIANG, S. **Training Issues in Industrial Ergonomics in The Occupational Ergonomics Handbook.** [s.l]: CRC Press, 1999.

LI, G.; RAJAGOPALAN, S. A Learning Curve Model with Knowledge Depreciation. **European Journal of Operational Research**, v. 105, p. 143-154, 1998.

- LI, G.; RAJAGOPALAN, S. The Impact of Quality on Learning. **Journal of Operations Management**, v. 15, p. 181-191, 1997.
- MAZUR, J. E.; HASTIE, R. Learning as Accumulation: a Reexamination of the Learning Curve. **Psychological Bulletin**, v. 85, n. 6, p. 1256-1274, 1978.
- MEHRA, K.; DHAWAN, S. K. Study of the Process of Organizational Learning in Software Firm in India. **Technovation**, v. 23, p. 121-129, 2003.
- MONTGOMERY, D. C. **Design and Analysis of Experiments**. 3.ed. Singapore: John Wiley & Sons, Inc., 1991.
- MONTGOMERY, D. C.; PECK, E. A. **Introduction to Linear Regression Analysis**. 2.ed. New York: John Wiley & Sons, Inc, 1992.
- MONTGOMERY, D. C.; RUNGER, G. C. **Applied Statistics and Probability for Engineers**. [s.l]: John Wiley & Sons, Inc, 1994.
- MUKHERJEE, A. S.; LAPRE, M. A.; VAN WASSENHOVE, L. N. Knowledge Driven Quality Improvement. **Management Science**, v. 44, p. 35-49, 1998.
- MUTH, E. J.; SPREMANN, K., Learning Effect in Economic Lot Sizing. **Management Science**, v. 29, p. 102-108, 1983.
- NAIM, M. M.; TOWILL, D. R. An Engineering Approach to LSE Modeling of Experience Curves in the Electricity Supply Industry. **International Journal of Forecasting**, v. 6, p. 549-556, 1990.
- NEMBHARD, D. A.; OSOTHSILP, N. Task Complexity Affects on Between-Individual Learning/Forgetting Variability. **International Journal of Industrial Ergonomics**, v. 29, p. 297-306, 2002.
- NEMBHARD, D. A.; UZUMERI, M. V. An Individual-Based Description of Learning within an Organization. **IEEE Transactions on Engineering Management**, v. 47, n. 3, p. 370-378, 2000a.

- NEMBHARD, D. A.; UZUMERI, M. V. Experimental Learning and Forgetting for Manual and Cognitive Tasks. **International Journal of Industrial Ergonomics**, v. 25, p. 315-326, 2000b.
- PANANISWAML, S.; BISHOP, R. C. Behavioral Implications of the Learning Curve for Production Capacity Analysis. **International Journal of Production Economics**, v. 24, p. 157-163, 1991.
- PICCININI, V. **Novas Formas de Organização do Trabalho na Indústria Calçadista**. Revista de Administração, USP, v. 27, n. 2, p. 33-40, Abr./Jun. 1992.
- PRAMONGKIT, P.; SHAWYUN, T.; SIRINAOVAKUL, B. Analysis of Technological Learning for the Thai Manufacturing Industry. **Technovation**, v. 20, p. 189-195, 2000.
- PRAMONGKIT, P.; SHAWYUN, T.; SIRINAOVAKUL, B. Productivity Growth and Learning Potentials of Thai Industry. **Technological Forecasting & Social Change**, v. 69, p. 89-101, 2002.
- RINK, D. R.; SWAN, J. E. Product Life Cycle Research: a Literature Review. **Journal of Business Research**, v. 7, n. 3, p. 219, 1979.
- SALAMEH, M. K.; ABDUL-MALAK, M. U.; JABER, M. Y. Mathematical Modelling of the Effect of Human Learning in the Finite Production Inventory Model. **Applied Mathematics Modelling**, v. 17, p. 613-615, 1993.
- SARASWAT, S. P.; GORGONE, J. T. Organizational Learning Curve in Software Installation: an Empirical Investigation. **Information & Management**, v. 19, p. 53-59, 1990.
- SEBER, G. A. F. **Multivariate Observations**. New York: John Wiley & Sons, Inc., 1984.
- SEREL, D. A.; DADA, M.; MOSKOWITZ, H.; PLANTE, R. D. Investing in Quality Under Autonomous and Induced Learning. **IIE Transactions**, v. 32, p. 545-555, 2003.
- SILVEIRA, G. da, BORESTEIN, D., FOGLIATTO, F. S. Mass Customization: Literature Review and Research Direction. **International Journal of Production Economics**, v. 72, p. 1-13, 2001.

SMUNT, T. L. Log-Linear and Non-Log-Linear Learning Curve Models for Production Research and Cost Estimation. **International Journal of Production Research**, v. 37, n. 17, p. 3901-3911, 1999.

SMUNT, T. L.; WATTS, C. A. Improving Operations Planning with Learning Curves: Overcoming the Pitfalls of “Messy” Shop Floor Data. **Journal of Operations Management**, v. 21, p. 93-107, 2003.

TAGUCHI, G.; CLAUSING, D. Robust Quality. **Harvard Business Review**, Jan-Feb, p. 65-75, 1990.

TAGUCHI, G.; ELSAYED, A. E.; HSIANG, T. **Taguchi – Engenharia da Qualidade em Sistemas de Produção**, McGrawHill, 1990.

TEPLITZ, C. J., **The Learning Curve Deskbook** : A reference guide to theory, calculations and applications. New York: Quorum Books, 1991.

TERWIESCH, C.; BOHN, R. Learning and Process Improvement During Production Ramp-Up. **International Journal of Production Economics**, v. 70, p. 1-19, 2001.

TOWILL, D. R. Forecasting Learning Curves. **International Journal of Forecasting**, v. 6, p. 25-38, 1990.

TOWILL, D. R. Management Systems Applications of Learning Curves and Progress Functions. **Engineering Costs and Production Economics**, v. 9, p. 369-383, 1985.

UZUMERI, M.; NEMBHARD, D. A Population of Learners: A New Way to Measure Organizational Learning. **Journal of Operations Management**, v. 16, p. 515-528, 1998.

VIGIL, D. P.; SARPER, H. Estimating the Effects of Parameter Variability on Learning Curve Model Predictions. **International Journal of Production Economics**, v. 34, p. 187-200, 1994.

VITS, J.; GELDERS, L. Performance Improvement Theory. **International Journal of Production Economics**, v. 77, p. 285-298, 2002.

WANG, F. K.; LEE, W. Learning Curve Analysis in Total Productive Maintenance. **Omega**, v. 29, p. 491-499, 2001.

WATERWORTH, C. J. Relearning the Learning Curve: a Review of the Derivation and Applications of Learning-Curve Theory. **Project Management Journal**, p. 24-31, March 2000.

WICKENS, C. D.; GORDON, S. E.; LIU, Y. **An Introduction to Human Factors Engineering**. [s.l.]: Addison Wesley Longman Inc., 1998.

WRIGHT, T. P. Factors Affecting the Cost of Airplanes. **Journal of the Aeronautical Sciences**, v. 3, 1936.

YELLE, L. E. Adding Life Cycles to Learning Curves. **Long Range Planning**, v. 16, n. 6, p. 82-87, 1983.

YELLE, L. E. Learning Curves: Interaction of Marketing and Production. **Industrial Marketing Management**, v. 9, p. 311-318, 1980.

YELLE, L. E. The Learning Curve: Historical Review and Comprehensive Survey. **Decision Science**, v. 10, 302-328, 1979.

YIN, R. K. **Estudo de Caso: planejamento e métodos**. 2.ed. Porto Alegre: Bookman, 2001.

ZANGWILL, W. I.; KANTOR, P. K. The Learning Curve: a New Perspective. **International Transactions in Operational Research**, v. 7, p. 595-607, 2000.

ZANGWILL, W. I.; KANTOR, P. K. Toward a Theory of Continuous Improvement and the Learning Curve. **Management Science**, v. 44, n. 7, 1998.

APÊNDICE 2 - Coeficientes do modelo de regressão gerados pela ponderação das variâncias

Equipe (X_1)	Família (X_2)	r_{ij} modelado	r_{ij} modelado médio	r_{ij} estimado (regressão ponderada)	Desvio relativo
1	1	147	146	146	0%
1	1	145			
2	1	167	122	95	-22%
2	1	156			
2	1	44			
3	1	10,5	66,8	45,0	-33%
3	1	123			
1	2	71,8	46,9	107,0	129%
1	2	42,6			
1	2	26,3			
2	2	59,6	69,8	73,0	5%
2	2	80			
3	2	30,9	38	39,0	2%
3	2	45,1			
1	3	68,7	68,7	69,0	0%
2	3	64,9	50,9	51,0	0%
2	3	36,8			
3	3	220	97,1	33	-66%
3	3	19,3			
3	3	52			
Desvio médio absoluto					29%

APÊNDICE 3 - Áreas geradas pelas 3 equipes na execução das operações relativas à Família

Fácil

Tempo de operação (min)	Área sob a curva		
	Equipe 1	Equipe 2	Equipe 3
60	43	49	106
120	98	113	237
180	160	187	383
240	227	266	537
300	298	351	698
360	373	439	863
420	450	530	1031
480	529	623	1202
540	611	719	1376
600	693	816	1551
660	777	914	1728
720	862	1013	1905
780	948	1114	2085
840	1035	1215	2265
900	1123	1317	2445
960	1212	1420	2627
1020	1301	1524	2809
1080	1390	1628	2992
1140	1480	1733	3176
1200	1571	1838	3360
1260	1662	1944	3544
1320	1754	2050	3729
1380	1845	2156	3914
1440	1938	2263	4099
1500	2030	2370	4285
1560	2123	2477	4471
1620	2216	2585	4658
1680	2309	2693	4844
1740	2403	2801	5031
1800	2497	2909	5218
1860	2591	3018	5406
1920	2685	3127	5593
1980	2779	3236	5781
2040	2874	3345	5969
2100	2969	3454	6157
2160	3064	3564	6345
2220	3159	3674	6533
2280	3254	3783	6722
2340	3349	3893	6910
2400	3445	4003	7099
2460	3541	4114	7288
2520	3636	4224	7477
2580	3732	4334	7666
2640	3828	4445	7855
2700	3924	4556	8045
2760	4021	4667	8234
2820	4117	4777	8424
2880	4213	4888	8613
2940	4310	4999	8803
3000	4406	5111	8993

Tempo de operação (min)	Área sob a curva		
	Equipe 1	Equipe 2	Equipe 3
3060	4503	5222	9182
3120	4600	5333	9372
3180	4697	5445	9562
3240	4794	5556	9752
3300	4891	5668	9942
3360	4988	5779	10133
3420	5085	5891	10323
3480	5182	6003	10513
3540	5279	6114	10704
3600	5377	6226	10894
3660	5474	6338	11085
3720	5571	6450	11275
3780	5669	6562	11466
3840	5766	6674	11656
3900	5864	6786	11847
3960	5962	6899	12038
4020	6059	7011	12229
4080	6157	7123	12420
4140	6255	7236	12610
4200	6353	7348	12801
4260	6451	7460	12992
4320	6549	7573	13183
4380	6647	7685	13374
4440	6745	7798	13565
4500	6843	7911	13757
4560	6941	8023	13948
4620	7039	8136	14139
4680	7137	8249	14330
4740	7235	8361	14521
4800	7334	8474	14713
4860	7432	8587	14904
4920	7530	8700	15095
4980	7629	8813	15287
5040	7727	8926	15478
5100	7825	9038	15670
5160	7924	9151	15861
5220	8022	9264	16053
5280	8121	9377	16244
5340	8219	9491	16436
5400	8318	9604	16627
5460	8417	9717	16819
5520	8515	9830	17011
5580	8614	9943	17202
5640	8712	10056	17394
5700	8811	10169	17586
5760	8910	10283	17778
5820	9009	10396	17969
5880	9107	10509	18161
5940	9206	10623	18353
6000	9305	10736	18545

APÊNDICE 3 - Áreas geradas pelas 3 equipes na execução das operações relativas à Família

Média

Tempo de operação (min)	Área sob a curva		
	Equipe 1	Equipe 2	Equipe 3
60	55	40	55
120	136	103	134
180	226	178	221
240	323	260	312
300	423	345	406
360	526	434	503
420	630	525	600
480	736	618	699
540	843	712	798
600	951	807	898
660	1059	903	999
720	1169	1000	1100
780	1278	1098	1202
840	1389	1197	1304
900	1499	1296	1406
960	1610	1395	1509
1020	1722	1495	1612
1080	1833	1595	1715
1140	1945	1695	1818
1200	2057	1796	1921
1260	2170	1897	2025
1320	2282	1998	2128
1380	2395	2100	2232
1440	2508	2202	2336
1500	2621	2304	2440
1560	2734	2406	2544
1620	2847	2508	2649
1680	2960	2610	2753
1740	3074	2713	2857
1800	3187	2816	2962
1860	3301	2919	3066
1920	3415	3022	3171
1980	3529	3125	3275
2040	3642	3228	3380
2100	3756	3331	3485
2160	3870	3434	3590
2220	3985	3538	3695
2280	4099	3641	3800
2340	4213	3745	3905
2400	4327	3849	4010
2460	4442	3952	4115
2520	4556	4056	4220
2580	4670	4160	4325
2640	4785	4264	4430
2700	4899	4368	4535
2760	5014	4472	4640
2820	5129	4576	4746
2880	5243	4680	4851
2940	5358	4785	4956
3000	5473	4889	5062

Tempo de operação (min)	Área sob a curva		
	Equipe 1	Equipe 2	Equipe 3
3060	5587	4993	5167
3120	5702	5098	5272
3180	5817	5202	5378
3240	5932	5307	5483
3300	6047	5411	5589
3360	6162	5516	5694
3420	6277	5620	5800
3480	6392	5725	5905
3540	6507	5829	6011
3600	6622	5934	6116
3660	6737	6039	6222
3720	6852	6144	6327
3780	6967	6248	6433
3840	7082	6353	6539
3900	7197	6458	6644
3960	7312	6563	6750
4020	7428	6668	6856
4080	7543	6773	6961
4140	7658	6878	7067
4200	7773	6983	7173
4260	7889	7088	7279
4320	8004	7193	7384
4380	8119	7298	7490
4440	8234	7403	7596
4500	8350	7508	7702
4560	8465	7613	7807
4620	8581	7718	7913
4680	8696	7823	8019
4740	8811	7928	8125
4800	8927	8033	8231
4860	9042	8139	8337
4920	9158	8244	8442
4980	9273	8349	8548
5040	9388	8454	8654
5100	9504	8560	8760
5160	9619	8665	8866
5220	9735	8770	8972
5280	9850	8876	9078
5340	9966	8981	9184
5400	10081	9086	9290
5460	10197	9192	9396
5520	10313	9297	9502
5580	10428	9402	9608
5640	10544	9508	9714
5700	10659	9613	9820
5760	10775	9719	9925
5820	10890	9824	10031
5880	11006	9930	10137
5940	11122	10035	10243
6000	11237	10141	10349