

**UNIVERSIDADE DE ARARAQUARA**  
**MESTRADO PROFISSIONAL EM ENGENHARIA DE PRODUÇÃO**

**Juliana Cotrim Garcia**

**CURVAS DE APRENDIZAGEM: ESTUDO DE CASO EM UMA  
INDÚSTRIA AERONÁUTICA**

Dissertação apresentada ao Programa de Mestrado Profissional em Engenharia de Produção da Universidade de Araraquara – UNIARA – como parte dos requisitos para obtenção do título de Mestre em Engenharia de Produção, Área de Concentração: Gestão Estratégica e Operacional da Produção.

**Profa. Dra. Ethel Cristina Chiari da Silva**  
**Orientadora**

**Araraquara, SP – Brasil**  
**2016**

## FICHA CATALOGRÁFICA

G199c Garcia, Juliana Cotrim

Curvas de aprendizagem: estudo de caso em uma indústria aeronáutica/Juliana Cotrim Garcia. – Araraquara: Universidade de Araraquara, 2017.

76f.

Dissertação (Mestrado)- Mestrado Profissional em Engenharia de Produção – Universidade de Araraquara-UNIARA

Orientador: Profa. Dra. Ethel Cristina Chiari da Silva

1. Curvas de aprendizagem. 2. Curvas de progresso. 3. Aprendizagem Organizacional. I. Título.

CDU 62-1

## REFERÊNCIA BIBLIOGRÁFICA

GARCIA, J.C. **Curvas de Aprendizagem: estudo de caso em uma indústria aeronáutica.** 2016.74f. Dissertação de Mestrado em Engenharia de Produção – Universidade de Araraquara, Araraquara-SP.

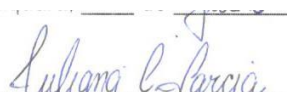
## ATESTADO DE AUTORIA E CESSÃO DE DIREITOS

NOME DO AUTOR: Juliana Cotrim Garcia

TÍTULO DO TRABALHO: Curvas de Aprendizagem: Estudo de caso em uma indústria aeronáutica

TIPO DO TRABALHO/ANO: Dissertação / 2016

Conforme LEI Nº 9.610, DE 19 DE FEVEREIRO DE 1998, o autor declara ser integralmente responsável pelo conteúdo desta dissertação e concede a Universidade de Araraquara permissão para reproduzi-la, bem como emprestá-la ou ainda vender cópias somente para propósitos acadêmicos e científicos. O autor reserva outros direitos de publicação e nenhuma parte desta dissertação pode ser reproduzida sem a sua autorização.



---

**Juliana Cotrim Garcia**

Universidade de Araraquara – UNIARA

Rua Carlos Gomes, 1217, Centro. CEP: 14801–340, Araraquara-SP

E-mail: [julianacotrim@outlook.com](mailto:julianacotrim@outlook.com)



UNIVERSIDADE DE ARARAQUARA - UNIARA  
MESTRADO PROFISSIONAL EM ENGENHARIA DE PRODUÇÃO

FOLHA DE APROVAÇÃO

Dissertação apresentada ao Programa de Mestrado Profissional em Engenharia de Produção da Universidade de Araraquara – UNIARA – para obtenção do título de Mestre em Engenharia de Produção.

Área de Concentração: Gestão Estratégica e Operacional da Produção.

NOME DO AUTOR: JULIANA COTRIM GARCIA

TÍTULO DO TRABALHO:

*"CURVAS DE APRENDIZAGEM: ESTUDO DE CASO EM UMA INDÚSTRIA AERONÁUTICA."*

Assinatura do(a) Examinador(a)

Conceito

Aprovado ( ) Reprovado

Prof(a). Dr(a). Ethel Cristina Chiari da Silva (orientador(a))  
Universidade de Araraquara - UNIARA

Aprovado ( ) Reprovado

Prof(a). Dr(a). José Luís Garcia Hermosilla  
Universidade de Araraquara - UNIARA

Aprovado ( ) Reprovado

Prof(a). Dr(a). Fábio Muller Guerrini  
Universidade de São Paulo - USP

Versão definitiva revisada pelo(a) orientador(a) em: 30 / 06 / 2017.

Prof(a). Dr(a). Ethel Cristina Chiari da Silva (orientador(a))

À minha família, em especial aos meus pais e a minha tia Ana Maria pela contribuição à minha formação em todos os aspectos e apoio em todos os momentos de minha vida.

## **AGRADECIMENTOS**

Agradeço meus pais, Sonia Maria Cotrim Garcia e Carlos Alberto Garcia por todo suporte e cuidado dedicados à mim por toda vida. Vocês são meu alicerce.

Meus avós Rita Garcia, Everal Luis Garcia e Albertina Rodrigues Cotrim por terem apoiado todos os meus sonhos de infância, da astronomia à alquimia.

Aos meus tios Ana Maria, Tude, Luis Henrique, Zeca, Ezequiel, Alfredo, Cida, Isabel, Edilene, Lourdes e primos Mariana, Bruno, Thiago e Leonardo por toda referência de base, família e união.

Ao meu irmão Leonardo Arctico Santana que, além de referência, é meu parceiro nesta vida. Minha admiração e carinho por você são imensos.

À Marli que embora não esteja mais entre nós, também esteve presente em todos os momentos que passei para chegar até aqui.

À minha orientadora prof. Dra. Ethel Cristina Chiari da Silva por abraçar a proposta do trabalho e me auxiliar em todo o desenvolvimento da pesquisa e ao prof. Dr. Jorge Alberto Achar por acreditar no trabalho e contribuir com sua aplicação.

E a Deus, por tudo que tem me proporcionado e todos que colocou em meu caminho.

E de cada pergunta minha vai nascendo a sombra imensa que envolve a posição dos olhos de  
quem pensa.  
Cecília Meireles

## RESUMO

A alta competitividade existente no mercado global tem conduzido as empresas a buscarem melhorias em seus processos continuamente a fim de reduzir os tempos e custos de fabricação. Neste contexto, a aprendizagem desempenha um papel fundamental uma vez que é a partir dela que novas e melhores formas de se produzir são descobertas à medida em que os trabalhadores se familiarizam com o processo por meio da repetição das tarefas à ele associadas. Diversos modelos de curvas de aprendizagem foram propostos na literatura para descrever o fenômeno da aprendizagem e auxiliar na previsão de tempos e custos futuros de produção, no entanto, a escolha do modelo mais adequado e dos parâmetros que devem ser utilizados ainda é um desafio para muitas empresas. Este trabalho buscou por meio de um estudo de caso comparar os modelos Stanford-B, DeJong e Curva-S com o clássico modelo de Wright por meio de testes estatísticos para avaliar se um ou mais deles seria mais adequado para aplicação em uma indústria do setor aeronáutico. A análise permitiu concluir que o modelo de Wright é o mais adequado quando os parâmetros utilizados são previamente definidos e que os modelos Stanford-B e DeJong também podem ser adotados quando os parâmetros são estimados estatisticamente.

**Palavras-chave:** Curvas de aprendizagem. Curvas de progresso. Aprendizagem organizacional.

## **ABSTRACT**

*The high competitiveness in the global market has led companies to continually seek for improvements in their processes in order to reduce manufacturing times and costs. In this context, learning plays a key role since it is from learning that new and better ways of producing are discovered as workers become familiar with the process through the repetition of the tasks associated with it. Several models of learning curves have been proposed in the literature to describe learning phenomena and to help to predict future times and costs. However, choosing the right model and the parameters that should be used is still a challenge for many companies. This work aimed to compare the Stanford-B, DeJong and Curva-S models with the classic Wright model through statistical tests to evaluate if one or more of them would be more suitable for application in an industry aeronautical. The analysis allowed to conclude that the Wright model is the most adequate when the parameters used are previously defined and that the Stanford-B and DeJong models can also be adopted when the parameters are estimated statistically.*

**Key-words:** *Learning curves. Progress curves. Organizational learning.*



## Lista de figuras

Figura 1 - Demonstração da curva de aprendizagem de Wright .....	25
Figura 2 - Distribuição das taxas de aprendizagem observadas em 22 estudos de campo (N=108) .....	37
Figura 3 - O declínio e aumento nas horas de trabalho devido à aprendizagem e ao esquecimento .....	42
Figura 4 - Comparação gráfica dos principais modelos potenciais .....	50
Figura 5 – Condução do estudo de caso .....	51
Figura 6 - Resultado da estatística de Anderson-Darling .....	56
Figura 7 - Análise de regressão nos valores plotados.....	57
Figura 8 – Resultado do teste de Dunnett.....	58
Figura 9 – Gráfico comparativo das curvas dos modelos com os dados reais .....	61

## **Lista de Tabelas**

Tabela 1 – Exemplo da etapa 4 utilizando o modelo de Wright.....	55
Tabela 2 – Estimativa dos parâmetros pelo método Bayesiano. ....	60

## **Lista de Abreviaturas e Siglas**

DIC - *Deviance Information Criterion.*

ERP – *Enterprise Resource Planning.*

MAPE - *Mean Absolute Percentual Error.*

PPCP – Planejamento, Programação e Controle da Produção.

MCMC – Monte Carlo via Cadeias de Markov.

## Sumário

<b>1 INTRODUÇÃO .....</b>	<b>12</b>
1.1 Contextualização .....	12
1.2 Problemática .....	15
1.3 Justificativa.....	18
1.4 Questão da pesquisa .....	20
1.5 Objetivo .....	20
1.6 Classificação metodológica .....	20
1.7 Estrutura do trabalho .....	21
<b>2 REVISÃO BIBLIOGRÁFICA.....</b>	<b>22</b>
2.1 Curvas de aprendizagem.....	22
2.2 Aplicações das curvas de aprendizagem .....	29
2.3 Taxas e fatores de aprendizagem.....	34
2.4 O fator esquecimento nas curvas de aprendizagem.....	41
2.5 Modelos de curvas de aprendizagem.....	45
2.5.1 Modelo de Wright.....	46
2.5.2 Modelo Stanford-B .....	48
2.5.3 Modelo DeJong .....	49
2.5.4 Modelo Curva-S .....	49
<b>3 MÉTODO DA PESQUISA.....</b>	<b>51</b>
<b>4 ESTUDO DE CASO.....</b>	<b>54</b>
4.1 Fase 1 – Aplicação dos modelos com parâmetros pré-estabelecidos .....	54
4.2 Fase 2 – Aplicação dos modelos com o auxílio dos estimadores Bayesianos.....	59
<b>5 CONCLUSÕES .....</b>	<b>63</b>
<b>REFERÊNCIAS .....</b>	<b>65</b>
<b>ANEXO A - PRINCIPAIS CURVAS DE APRENDIZAGEM.....</b>	<b>70</b>
<b>APÊNDICE A - BREVE REVISÃO DA METODOLOGIA BAYESIANA</b>	<b>71</b>

# 1 INTRODUÇÃO

## 1.1 Contextualização

A incessante competição vivenciada pelas organizações ao longo dos anos tem promovido um incentivo contínuo para que as companhias busquem por novas e melhores formas de se produzir e neste contexto, a aprendizagem desempenha um papel fundamental uma vez que a partir dela as empresas tem obtido melhorias constantes em seus processos e por consequência tem reduzido os tempos e custos associados à fabricação de seus produtos ou prestação de seus serviços.

No início da década de 60, Hirschmann (1964) observou que as melhorias progressivas resultantes desta busca são consistentes com a experiência de que uma tarefa pode sempre ser feita mais eficientemente a cada nova tentativa sucessiva. Para o autor, isso ocorre porque as pessoas sempre aprendem e elas aprendem sob um padrão geralmente previsível, o que também foi observado por Hartley (1965) no ano seguinte ao afirmar que os resultados da aprendizagem são regulares o suficiente para serem previstos. Os autores concordam que é a regularidade da aprendizagem que a torna previsível permitindo que seja modelada matematicamente por meio das curvas de aprendizagem, gráficos que representam o decréscimo dos tempos ou custos de produção à medida em que a quantidade acumulada de um produto aumenta. As curvas de aprendizagem utilizam como principal parâmetro ou variável uma taxa de aprendizagem que é um valor percentual utilizado para definir como o decréscimo da curva deverá ocorrer.

A experiência mencionada por Hirschmann em 1964 se relaciona com a hipótese proposta pela teoria da curva de aprendizagem, a qual segundo Argote (2012) supõe que a quantidade de horas de trabalho necessária para executar determinada tarefa tende à decrescer à medida em que novas repetições são efetuadas. Este fenômeno foi observado primeiramente por Wright (1936) na indústria aeronáutica e posteriormente explorado ao longo dos anos por diversos autores ao observarem que quanto mais as organizações produziam determinado produto, mais vezes as tarefas ou atividades necessárias para produzi-lo eram repetidas pelos trabalhadores e, conseqüentemente, aumentava a experiência e o aprendizado deles com essas tarefas, o que resultava na diminuição dos tempos e por conseguinte dos custos associados a essas tarefas. (ARGOTE; EPPLE, 1990; ARGOTE; 2012; DUTTON; THOMAS, 1984; HOCKENBERRY, 2008; JABER; BONNEY, 1999; NEMET, 2006).

No início da década de 70, Albernathy (1974) afirmou que o simples mas poderoso conceito de que o custo do produto declina sistematicamente por uma determinada porcentagem cada vez que o volume de sua produção dobra é muito importante porque isso significa que o volume crescente deste produto e de sua participação no mercado também trará vantagens de custo sobre a competitividade que existe entre as organizações. Essa vantagem foi observada também na década de 80 por Spence (1981) ao verificar que a curva de aprendizagem cria barreiras de entrada e proteção no mercado ao conferir vantagens de custo sobre novos entrantes para as organizações que alcançam fatias largas do mercado embora essas vantagens de custo não sejam permanentes. Para o autor, esta vantagem existe porque segundo a teoria da curva de aprendizagem, conforme a quantidade acumulada de produtos fabricados aumenta, ocorre um declínio na quantidade de horas necessárias para fabricá-los e conseqüentemente nos custos de fabricação. Portanto, organizações que possuem fatias maiores do mercado e por este motivo produzem mais produtos, adquirem também mais experiência reduzindo o tempo e o custo unitário de fabricação ao longo do período.

No início da década de 90 outras vantagens relacionadas à aplicação das curvas de aprendizagem como um fator benéfico à competitividade das organizações foram observadas por Cabral e Riordan (1994). Esses autores listaram os benefícios decorrentes da hipótese de que o custo unitário de um produto decresce com o acúmulo de sua produção (como a teoria da curva de aprendizagem supõe) indicando que existem diversas implicações estratégicas contidas nesta possibilidade, destacando-se dentre elas a vantagem competitiva que as empresas podem obter frente aos seus concorrentes movendo suas curvas de aprendizagem mais rapidamente do que eles. Segundo os mesmos autores, a busca por vantagem competitiva faz com que as organizações busquem melhorias em seus processos produtivos continuamente para reduzir os tempos e custos de fabricação de seus produtos.

Ainda nesta época, Smunt (1996) também observou a importância da teoria da aprendizagem no suporte à tomada de decisão nas organizações. O autor afirma que quando a aprendizagem é uma parte significativa do ambiente produtivo, projeções mais acuradas da capacidade da fábrica são possíveis por meio da utilização das curvas de aprendizagem e isso permite que decisões acerca do planejamento e gerenciamento dessa capacidade sejam tomadas mais efetivamente. Para o autor, isso é possível porque a aprendizagem é um fenômeno que ocorre naturalmente diante da repetição de determinada tarefa e seus efeitos deveriam ser considerados nas etapas de planejamento uma vez que influenciam diretamente os índices de produtividade no chão de fábrica.

No final da década de 90, Uzumeri e Nembhard (1998) observaram que a utilização das curvas de aprendizagem para o aumento da eficiência da fabricação e redução dos custos já havia sido demonstrada convincentemente ao longo dos anos, levando as organizações a fazer uso de sua experiência para melhorar suas operações, realizando o mesmo trabalho com um custo unitário menor.

Nessa mesma época, Kapp (1999) constatou que para muitos especialistas a única vantagem sustentável que uma organização teria no futuro seria sua habilidade de aprender mais rápido do que seus competidores e essa vantagem competitiva poderia ser alcançada transformando a organização em uma organização de aprendizagem.

Anos mais tarde, Pisano (2016) observou que a competição entre as empresas existe em dois níveis: o primeiro nível de competição se refere ao produto que encontra-se disponível no mercado e seus atributos sendo portanto mais visível. O segundo nível é menos visível para os que estão de fora uma vez que se refere à competição que existe para criar capacidades operacionais, organizacionais e tecnológicas nas organizações e é neste último nível que a aprendizagem está inserida, sendo a aprendizagem adquirida a partir da experiência um mecanismo crítico pelo qual as empresas intensificam suas capacidades existentes.

Neste contexto, a utilização das curvas de aprendizagem torna-se essencial para auxiliar as organizações na competição que existe entre elas pois, como constataram Jaber e Guiffrida (2004), é por meio dela que as organizações podem medir quão rápido aprendem e fazer uso desta informação para suportar a tomada de decisão no nível estratégico, tático ou operacional, garantindo uma melhor ocupação dos recursos produtivos e conseqüentemente uma maior vantagem nesta competição.

Nembhard e Uzumeri (2000) afirmam que à medida em que o ambiente se torna cada vez mais competitivo para proporcionar aos clientes uma maior variedade de produtos, as empresas se movem em direção a ciclos mais curtos de produção e, neste contexto, além das mudanças frequentes de produto, a aprendizagem e o esquecimento aos quais os trabalhadores estão submetidos assumem um papel crucial pois, para os autores, é necessário que esses trabalhadores aprendam constantemente novas habilidades, tecnologias e processos com a finalidade de manter o movimento em direção a ciclos menores de produção. Como conseqüência, a aprendizagem e principalmente sua retenção pelo trabalhador se torna um fator crítico quando se trata da produtividade uma vez que exerce influência direta sobre ela.

Badiru (2012) afirma que capturar o processo de aprendizagem em um *framework* quantitativo é essencial para tomar decisões efetivas em qualquer operação pois, quando captura-se este fenômeno é possível obter uma visão do futuro da produção de determinado produto em termos de ciclo ou custos incorridos, o que contribui para uma melhor definição da estratégia, entre outros benefícios proporcionados pela aplicação das curvas de aprendizagem nas organizações.

A relevância da teoria da curva de aprendizagem em um cenário de alta competitividade entre as organizações também foi observada por Grosse, Glock e Müller (2015) ao afirmarem que ainda que o conceito de curvas de aprendizagem na área de economias de produção tenha sido introduzido há quase um século, ainda é de suma importância para as organizações seja como um medidor de performance, um suporte na definição de padrões de trabalho, uma ferramenta de previsão ou mesmo uma ferramenta de suporte à decisão.

## **1.2 Problemática**

Diversos modelos de curva de aprendizagem foram desenvolvidos ao longo dos anos e, embora o modelo que Theodore Paul Wright desenvolveu em 1936 seja o mais amplamente utilizado nas indústrias para modelar o fenômeno da aprendizagem devido a sua estrutura simples e boa capacidade de aderência aos dados empíricos como afirmaram Anzanello e Fogliatto (2005), desde de sua divulgação diversas curvas de aprendizagem foram desenvolvidas e aplicadas na área de economias de produção conforme constataram Grosse, Glock e Müller (2015).

Desde a década de 70 pesquisadores vem constatando que outros modelos tem sido adotados pelas organizações, pois conforme afirmou Yelle (1979), alguns fabricantes encontraram modelos que melhor descreviam suas experiências com o fenômeno da aprendizagem na manufatura ao longo dos anos. Para o autor, a adoção de outros modelos se deve a não aderência do clássico modelo de Wright a todos os tipos de indústrias e produtos e um problema relacionado a este modelo é que os fabricantes de aeronaves tem, por muito tempo e em grande parte, operado com a curva de aprendizagem utilizando uma taxa de aprendizagem de 80%, valor proposto inicialmente por Wright em 1936, e a adoção desse pressuposto pelas indústrias posteriormente não levou em consideração a margem de erro nem as diferenças entre os tipos de aeronaves fabricadas.



No entanto, até meados da década de 90 ainda que numerosos modelos de curva de aprendizagem tenham sido apresentados na literatura, o modelo log-linear desenvolvido por Wright em 1936 a partir de estudos na indústria aeronáutica ainda era reconhecido como o modelo básico para grande parte das análises de produtividade na fabricação como observou Badiru (1994). Essa observação foi complementada por Dar-El (2000) anos mais tarde ao verificar que engenheiros de produção quase sempre fizeram uso do modelo proposto por Wright sem considerar as características dos operadores ou mesmo as circunstâncias nas quais o trabalho é executado.

Jaber e Guiffrida (2008) observaram que apesar de sua popularidade, o modelo de curva de aprendizagem de Wright possui limitações e não deveria ser considerado um modelo universal. Dentre as limitações do modelo, os autores destacaram a premissa existente nele de que o fenômeno da aprendizagem continua indefinidamente ao longo do período de fabricação contrariando um comportamento conhecido como platô - observado nos dados de diversas curvas de aprendizagem - no qual o decréscimo da quantidade de horas necessárias para a produção de determinado produto cessa em determinado instante. Ignorar o efeito platô faz com que as horas necessárias para produzir determinado produto tendam à zero nos casos em que a curva de aprendizagem for aplicada em produções de larga escala que atingem facilmente dezenas de milhares de produtos.

Embora reconheçam o potencial do modelo de Wright nas aplicações das curvas de aprendizagem relacionadas à indústria aeronáutica, Moore et al. (2015) efetuaram uma pesquisa na área de aquisições do setor de defesa do governo americano para a indústria aeronáutica e afirmaram que este modelo existe há mais de 75 anos e, por este motivo, não deveria ser aceito como status quo somente por sua simplicidade ou por nostalgia. Para os autores, se existir um modelo de curva de aprendizagem mais preciso que possa ser aplicado para efetuar estimativas, ele deveria ser investigado e considerado. Para verificar a existência de um modelo mais preciso que o de Wright, esses pesquisadores compararam este modelo com outros três modelos apresentados na literatura: Stanford-B, DeJong e Curva-S e apesar de não chegarem a conclusão se existe ou não um modelo mais preciso que o de Wright para a utilização no setor estudado, os autores verificaram a importância das variações no fator de incompressibilidade "M", um parâmetro utilizado pelos modelos DeJong e Curva-S que refere-se ao nível de automação da fábrica podendo variar de 0 à 1 para indicar se o processo é pouco ou muito automatizado, na verificação da aderência destes modelos aos dados reais, o que demonstra que não somente a escolha do modelo de curva de aprendizagem é importante,

mas também a escolha dos parâmetros mais adequados utilizados por alguns modelos para cada tipo de aplicação.

Diante da diversidade de modelos desenvolvidos ao longo dos anos, a escolha do modelo que melhor representa o fenômeno de aprendizagem na produção ainda é um dilema, pois, conforme Grosse, Glock e Müller (2015) observaram, ainda que a aplicação das curvas de aprendizagem seja conhecida há muitos anos, surpreendentemente a questão de como diferentes curvas de aprendizagem trabalham e qual curva de aprendizagem utilizar em cada aplicação ainda não foi tratada em um estudo específico para isso. Os autores afirmaram ainda que pesquisadores e praticantes passam pelo problema de selecionar uma curva apropriada de aprendizagem cada vez que os efeitos de aprendizagem são modelados, o que pode ser desafiador e consumir muito tempo dado o largo número de curvas de aprendizagem que foram desenvolvidas no passado.

Outra dificuldade relacionada com a aplicação das curvas de aprendizagem se deve ao fato de que muitas vezes as indústrias carecem de dados históricos da produção, no entanto, Bailey e McIntyre (1997) afirmaram que nestes casos, as empresas que utilizam curvas de aprendizagem para estimar os custos de mão de obra de novos produtos devem fazer uma suposição do modelo apropriado de curva de aprendizagem e da taxa de aprendizagem associada ou esperar até que dados suficientes estejam disponíveis para testar modelos alternativos e estimar seus parâmetros, porém, estes dois procedimentos não são mutuamente exclusivos uma vez que suposições iniciais podem ser refinadas conforme dados adicionais se tornam disponíveis.

Além da dificuldade enfrentada por pesquisadores na escolha do modelo de curva de aprendizagem mais adequado para cada aplicação, Grosse, Glock e Müller (2015) notaram que apesar de inúmeros trabalhos terem sido publicados após o trabalho de Wright, os pesquisadores ainda encontram também dificuldade para estimar os parâmetros associados às curvas de aprendizagem

A indústria na qual este estudo de caso foi desenvolvido faz uso do modelo clássico de Wright em suas previsões de curva de aprendizagem, no entanto, nenhum outro modelo foi testado até o momento para verificar se existe uma curva de aprendizagem mais apropriada para aplicação e quais parâmetros melhor modelariam o fenômeno de aprendizagem neste caso.

### 1.3 Justificativa

Sabe-se que nos últimos anos o bom desempenho de uma organização se tornou um fator crucial para garantir sua sobrevivência em um cenário de competitividade global e neste contexto, as curvas de aprendizagem são muito úteis para suportar as melhorias de desempenho devido ao impacto positivo que a aprendizagem exerce nas organizações conforme observou Badiru (2012).

Beneito, Engracia e Sanchis (2014) constataram que a análise dos processos de aprender-fazendo e seu papel na formação de capital humano, e por sua vez, na produtividade da empresa, tem sido um campo muito atrativo para pesquisas pois, como complementam Argote (2012) e Badiru (2012), os ganhos de produtividade gerados pela aprendizagem são significantes dado que as reduções nos tempos de processamento das operações alcançadas pelas curvas de aprendizagem podem traduzir-se diretamente em economias de custo. Por esse motivo, pesquisadores têm analisado os efeitos da repetição de determinada tarefa sobre o tempo necessário para executá-la e os benefícios obtidos por sua aplicação nos diversos setores industriais ou prestadores de serviços há muito tempo (BENEITO, 2014; JABER e BONNEY, 1996; THOMASSEN, 1998).

Desde a década de 60 os benefícios da aprendizagem nas economias de custo e consequentemente na performance da organização são evidenciados pois, como observou Hartley (1965) na indústria aeronáutica, embora os custos com mão de obra direta representem apenas 20% do custo total de produção de uma aeronave, quando recorda-se que o custo médio de sua produção pode facilmente alcançar cerca de meio milhão de libras ou mais, parece razoável concluir que economias geradas pela aprendizagem podem sim ter um efeito substancial no custo unitário de uma aeronave gerando benefícios significativos para a organização.

Anos mais tarde, Albertnathy (1974) observou que muitas companhias construíram suas estratégias de produção e marketing em torno da curva de aprendizagem e para o autor, os gerentes que conseguem identificar os possíveis efeitos do fenômeno da aprendizagem podem antecipá-los em seus planos escolhendo estratégias alternativas para se sobressair em um cenário de alta competitividade. Para Yelle (1979) a importância de considerar os efeitos da curva de aprendizagem nos planos de produção se deve ao fato de que para uma força de trabalho fixa, a capacidade tende a se expandir automaticamente a medida em que a aprendizagem cresce, pois a quantidade de horas necessárias para a produção de determinado produto tende a decrescer com o aumento da experiência adquirida em sua produção e

existem implicações significativas neste fenômeno sob o ponto de vista do planejamento uma vez que incorporar o fenômeno da aprendizagem no modelo de planejamento aumenta sua precisão, pois traz informações mais realistas tornando-o mais preciso.

Na década de 80, a vantagem de se explorar o fenômeno da aprendizagem nas organizações foi enfatizada por Dutton e Thomas (1984) ao afirmarem que o entendimento das relações causais na variabilidade das taxas de aprendizagem pode ajudar os gerentes de produção e que dada a complexidade de sua dinâmica, compreender os elementos das curvas de aprendizagem e como influenciá-los pode se traduzir em vantagem competitiva para as organizações que conseguirem esse feito.

Posteriormente Smunt (1996) verificou que os benefícios de se utilizar a análise fornecida pelas curvas de aprendizagem eram conhecidos há mais de três décadas e para o autor a metodologia de planejamento da capacidade deveria considerar os efeitos das futuras melhorias de produtividade previstos por meio das curvas de aprendizagem no dimensionamento da utilização da capacidade deixando suas estimativas mais precisas. O setor responsável pelo planejamento da capacidade em uma organização é o Planejamento, Programação e Controle da Produção (PPCP) que, segundo Pedroso e Corrêa (1996), é responsável por decisões sobre o que, quando e onde produzir ou comprar, decisões estas que, segundo os autores, condicionam o desempenho interno da manufatura e conseqüentemente o desempenho externo de uma organização, garantindo sua sobrevivência no mercado. Para tomar essas decisões, diversas ferramentas e metodologias são utilizadas pelo PPCP, incluindo-se entre elas a curva de aprendizagem, utilizada na previsão das horas necessárias para fabricar determinado produto e seu custo unitário ao longo do tempo, daí a importância de se utilizar os modelos de curva de aprendizagem mais apropriados para a organização permitindo com que esta obtenha dados precisos para suportar suas decisões em todos os níveis.

Moore et al. (2015) também enfatizam a importância de se utilizar uma curva de aprendizagem adequada para garantir a consistência dos dados obtidos que serão utilizados para suportar a tomada de decisões na organização, pois segundo os autores, uma forma de auxiliar as estimativas e conseqüentemente os tomadores de decisão é provê-los com as ferramentas mais atuais e apropriadas para o cálculo de previsões mais precisas e confiáveis.

Neste contexto, torna-se crucial selecionar um modelo de curva de aprendizagem que melhor representa o fenômeno da aprendizagem no chão de fábrica, permitindo que as previsões efetuadas pelo PPCP sejam precisas e as decisões tomadas com base nessas

previsões sejam assertivas, por isso neste trabalho outros modelos propostos na literatura são comparados ao tradicional modelo proposto por Wright em 1936 com a finalidade de verificar se existe um modelo mais preciso para aplicação em um determinado tipo de aeronave de uma indústria aeronáutica. Além da seleção de um modelo adequado para descrever o fenômeno da aprendizagem na organização, é importante também avaliar os parâmetros utilizados pelos modelos de curva de aprendizagem a fim de se obter os parâmetros mais adequados para representar este fenômeno deixando os modelos mais precisos para melhor suportar a tomada de decisão na organização.

#### **1.4 Questão da pesquisa**

Dada a importância das curvas de aprendizagem no suporte à decisão dentro das organizações, a escolha de um modelo apropriado que forneça informações mais precisas à respeito dos efeitos da aprendizagem nos índices de produtividade se faz necessária e, portanto, esta pesquisa visa responder a seguinte questão:

Existe um modelo de curva de aprendizagem potencial exposto na literatura que seja mais acurado que o de Wright (1936) para aplicação na indústria aeronáutica, especificamente no setor de defesa e segurança?

#### **1.5 Objetivo**

O objetivo deste trabalho é comparar a curva de aprendizagem proposta por Wright (1936) com os modelos potenciais Standford-B, DeJong e Curva-S por meio de uma aplicação em uma empresa de grande porte do setor aeronáutico, mais especificadamente no setor de defesa e segurança.

#### **1.6 Classificação metodológica**

Esta pesquisa compreende um estudo de caso realizado em uma indústria do setor aeronáutico, especificadamente na área de Defesa e Segurança para avaliar a existência de um ou mais de um modelo de curva de aprendizagem que seja mais preciso que o modelo de Wright utilizado atualmente pela organização.

De natureza aplicada, a pesquisa é caracterizada como descritiva sob o ponto de vista de seus objetivos e quantitativa quanto à sua abordagem uma vez que se utiliza de análises

numéricas para avaliar os modelos selecionados (Standford-B, DeJong e Curva-S) e estimar seus parâmetros.

A amostra foi selecionada de modo intencional pela pesquisadora, que coletou dados de horas apontadas de 18 unidades de um tipo de aeronave fabricadas sequencialmente. Os instrumentos de coleta dos dados foram documentos e informações fornecidos pela própria empresa.

## **1.7 Estrutura do trabalho**

O trabalho está estruturado em cinco seções, todas descritas abaixo.

A seção 1 apresenta uma contextualização sobre o tema escolhido, a justificativa para a escolha deste tema e sua relevância, bem como a problemática relacionada à ele. Apresenta-se também a questão da pesquisa, seus objetivos e o método selecionado.

Na seção 2 é efetuada uma revisão bibliográfica a respeito do tema curvas de aprendizagem apresentando sua definição, suas principais aplicações, os fatores que o permeiam, a questão do esquecimento dentro do tema curvas de aprendizagem e uma apresentação dos modelos selecionados para a realização desta pesquisa.

Na seção 3 detalha-se o método da pesquisa apresentando-se as etapas de sua aplicação conforme um modelo de condução de estudo de caso proposto pela literatura.

Na seção 4 o estudo de caso é apresentado com uma breve introdução sobre a empresa na qual o trabalho foi desenvolvido, a descrição da aplicação e os resultados obtidos.

As conclusões referentes aos resultados obtidos no estudo de caso, bem como as sugestões para a organização são apresentadas na seção 5.

## 2 REVISÃO BIBLIOGRÁFICA

Nesta seção o conceito de curva de aprendizagem é apresentado juntamente com a exemplificação de suas principais aplicações em diferentes áreas da indústria. A dificuldade de se escolher uma taxa de aprendizagem mais representativa do fenômeno do aprendizado em cada setor é exposta assim como o fator esquecimento também presente no contexto de curvas de aprendizagem. Por fim, os principais modelos de curvas de aprendizagem são demonstrados.

### 2.1 Curvas de aprendizagem

De acordo com Silayio, Migunga e Shemwetta (2014), a aprendizagem é o processo de adquirir conhecimento ou habilidade por meio de estudos ou experiências. No setor industrial, diversos pesquisadores concluíram que a aprendizagem pode ser determinada como um fenômeno resultante da experiência ou familiaridade com o produto ou processo adquiridas pelos trabalhadores por meio da repetição contínua de tarefas na medida em que a produção acumulada de determinado produto aumenta tendo como principal efeito o aumento da produtividade no chão de fábrica e a consequente redução do custo unitário de fabricação. (ARGOTE E EPPLE, 1990; DAR-EL, 2000; HARTLEY, 1965; YELLE; 1979). Essa familiarização também foi observada recentemente por Moore (2015) que a colocou como o fator que leva o trabalhador a precisar de cada vez menos tempo para completar uma mesma tarefa à medida em que ele a executa repetidas vezes.

Para Badri et al. (2016), os trabalhadores tem passado pelo processo de aprendizagem que também é conhecido como aprender-fazendo e este fenômeno ou sintoma pode ser explicado por meio das curvas de aprendizagem que, segundo Badiru (1994) e Anzanello e Fogliatto (2005), são representações matemáticas do desempenho de um trabalhador quando submetido à uma tarefa repetitiva na qual o tempo de execução tende à decrescer sob uma taxa específica à medida em que novas repetições são efetuadas.

No início da década de 60, Hirschmann (1964) observou que o fenômeno descrito pelas curvas de aprendizagem é algo muito natural uma vez que todos sabem que a prática leva a perfeição e uma atividade pode sempre ser feita de uma forma melhor não apenas pela segunda vez, mas cada vez que for executada sucessivamente, o que também foi constatado anos mais tarde por Badiru (2012) ao afirmar que aprender, desaprender e reaprender é um processo comum para as pessoas.

Já na década de 70, Yelle (1979) constatou que as primeiras unidades de um produto são produzidas de forma ineficiente porque quando operadores novos ou não habilidosos executam uma tarefa pela primeira vez, eles não podem esperar fazê-la no que seria considerado um tempo aceitável e um certo período de tempo ou um certo número de ciclos devem ser permitido ao operador para ganhar familiaridade com os movimentos necessários com a finalidade de aumentar a velocidade na execução da tarefa. O autor ainda afirma que com base nas curvas de aprendizagem, algumas indústrias estimam o tempo padrão para um determinado número de série ou lote estabelecendo que a partir dele haverá pouco ou nenhum decréscimo na quantidade de horas necessárias para sua fabricação.

Anos mais tarde, Fioretti (2007) também observou que novas linhas de montagem estão sujeitas a diversos problemas e atrasos nos prazos porém, para o autor, os gerentes de produção já sabem que a primeira unidade será produzida ineficiente bem como sabem que rapidamente um processo de aprendizagem será iniciado e cedo ou tarde o tempo de produção começará a decrescer, aumentando a produtividade e ampliando a capacidade da fábrica. Essa ampliação ocorre porque uma vez que menos tempo será requerido para completar as tarefas, os trabalhadores terão mais tempo livre para absorver outras atividades ou mesmo operar em outros processos ou produtos.

Sabe-se que o fenômeno da aprendizagem é inerente ao processo produtivo devido à repetição de tarefas que existe na fabricação de produtos ou prestação de serviços e por esse motivo Jaber e Bonney (2007) afirmaram que ele não pode ser ignorado, principalmente quando um operador inicia a produção de um novo produto, muda para uma nova máquina, retoma a produção após um intervalo de tempo ou implementa uma nova técnica de produção. Isso ocorre porque como Thomassen (1998) havia explicado anteriormente, a aprendizagem envolve a descoberta de melhores formas de organizar o trabalho por meio da melhoria de métodos e da especialização nas tarefas, bem como ocorre a partir do atingimento de uma performance melhor com os equipamentos utilizados ao passo em que os trabalhadores se familiarizam com eles no ambiente produtivo.

De acordo com Kredler (2014), os primeiros estudos empíricos com curvas de aprendizagem remetem ao final do século 19 e são provenientes da literatura da área da psicologia, o que foi anteriormente verificado também por Argote (2012) quando afirmou que os psicólogos foram os primeiros a descobrirem as curvas de aprendizagem porém, esses pesquisadores focaram no comportamento do indivíduo e somente mais tarde foram encontradas análises registradas de curvas de aprendizagem nos níveis organizacionais.

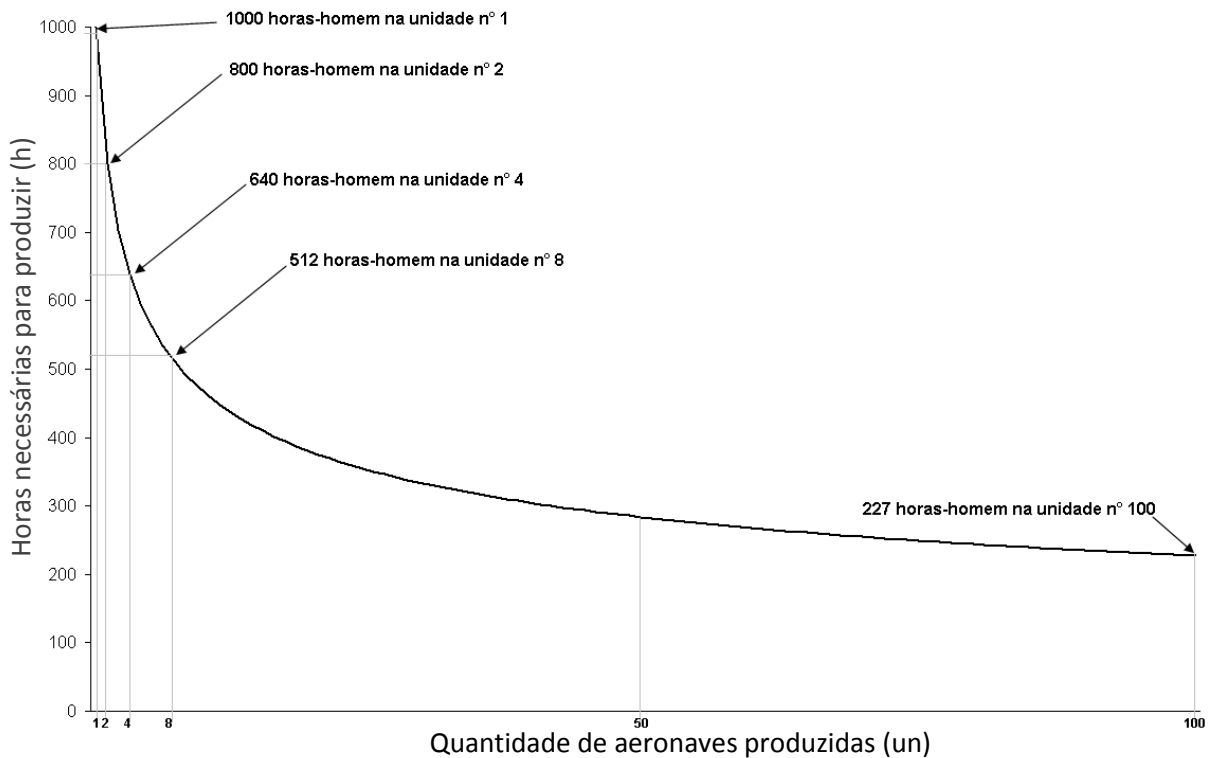


Grahame (2010) afirmou que as origens da curva de aprendizagem remetem ao século passado, sendo que a primeira observação da curva de aprendizagem na manufatura ocorreu em 1925 quando gerentes notaram que o número de horas-homem para montar aeronaves decrescia conforme mais aeronaves eram produzidas, o que foi subsequentemente demonstrado por Theodore Paul Wright em 1936, quando o pesquisador estabeleceu a partir de sua pesquisa na indústria aeronáutica que era possível prever com acurácia quanto tempo de trabalho seria necessário para produzir aeronaves no futuro.

O primeiro pesquisador a demonstrar o efeito da aprendizagem na manufatura, especificamente na indústria aeronáutica, foi Theodore Paul Wright em 1936 que, ao levantar os fatores que influenciavam a variação dos custos da produção de aeronaves identificou entre eles o fenômeno da aprendizagem ao observar que à medida em que as aeronaves de um determinado modelo eram produzidas, as horas de trabalho necessárias para produzi-las decresciam. O pesquisador também constatou que esse decréscimo ocorria sob uma taxa constante de 20% cada vez que a quantidade acumulada dobrava ou seja, o produto passava a requisitar apenas 80% das horas necessárias para produzi-lo comparado com o período antes da quantidade acumulada dobrar, sendo este percentual denominado taxa de aprendizagem.

Na década de 60, Hartley (1965) exemplificou a aplicação do modelo de Wright considerando uma aeronave X que requer 1000 horas-homem de mão de obra direta para produzir a primeira unidade. Segundo o autor, as fabricantes de aeronaves verificaram que a segunda unidade da aeronave X irá requerer apenas 800 horas-homem (80% da primeira), a quarta unidade irá utilizar 640 horas-homem (80% da segunda) e a oitava unidade irá requerer 512 horas-homem (80% da quarta) para ser produzida, como é possível observar na figura 1.

Figura 1 - Demonstração da curva de aprendizagem de Wright



Fonte: Hartley (1965, p. 123)

Ainda nessa época, Hirschmann (1964) observou que a redução do número de horas-homem à uma taxa regular ao longo de uma vasta gama de produção observada por Wright tratava-se de uma melhoria contínua tão comum na indústria aeronáutica que se tornou a expectativa normal na produção em massa de aeronaves nos tempos de guerra e que, a partir dela, a produção e outros tipos de atividades também foram habitualmente programadas em alguma base de melhoria progressiva.

Apesar de ter sido desenvolvida na década de 30, a curva de aprendizagem se popularizou alguns anos mais tarde, pois como Yelle (1979) observou, a curva de aprendizagem começou a receber atenção durante a Segunda Guerra Mundial (1939–1945) quando os contratantes do governo buscaram por formas que eles poderiam utilizar para prever custos e requisitos de tempo para a construção de navios e aeronaves para serem utilizados na condução da guerra, no entanto, conforme afirma Dar-El (2000), as curvas de aprendizagem foram amplamente utilizadas em outras indústrias após a guerra tais como a naval, petróleo e automotiva, quando elas começaram a ganhar maior notabilidade e verificou-se que eram aplicáveis em outros tipos de produtos e processos produtivos, sendo gradativamente adotada por empresas privadas naquele período.

O fenômeno da aprendizagem nas indústrias foi analisado ao longo dos anos sob, pelo menos, duas perspectivas: sua ocorrência no nível organizacional, a qual se refere à melhoria da organização como um todo desde seus ferramentais até as alterações de normas, procedimentos e da tecnologia empregada que resulta na redução dos tempos de fabricação aumentando a produtividade e reduzindo os custos de produção e sua ocorrência no nível individual que se refere basicamente ao aumento da proficiência dos trabalhadores por meio do aprendizado adquirido a partir da execução de tarefas repetidas vezes, o que resulta na diminuição dos tempos necessários para executá-las.

Por causa da divergência entre as perspectivas do nível em que a aprendizagem ocorre na empresa, as curvas de aprendizagem receberam diferentes nomes ao longo dos anos, pois, como Yelle (1979) constatou ainda na década de 70, vários autores haviam se referido às curvas de aprendizagem como curvas de progresso, curvas de melhoria e curvas de experiência, sendo este último tipo também evidenciado por Badiru (1994). Anos mais tarde Dar-el (2000) sugeriu que o termo “curvas de progresso” fosse utilizado para o nível organizacional enquanto o termo “curvas de aprendizagem” fosse utilizado para a aprendizagem no nível individual, no entanto, recentemente Attia, Megahed e Duquenne (2016) afirmaram que essa divergência entre perspectivas relacionadas ao nível da aprendizagem se deve ao fato de que é muito difícil distinguir a aprendizagem individual e organizacional uma vez que a configuração industrial requer a integração de uma variedade enorme de processos para formar o produto final.

No nível organizacional, a diminuição dos tempos e custos da produção de determinado produto evidenciada por meio das curvas de aprendizagem é o resultado de melhorias que vão além da redução da duração das tarefas devido ao aumento da proficiência dos trabalhadores. Neste nível, o declínio das horas também se deve às alterações de tecnologia, trocas de equipamentos e ferramentais, mudanças nos processos, melhorias na gestão, entre outros fatores.

Na década de 90, Smunt (1996) observou que as melhorias na performance da organização não eram obtidas somente a partir do aumento da proficiência dos trabalhadores, mas também de melhorias nos equipamentos, ferramentais e na própria gestão associando o melhor desempenho na produção com o processo de aprendizagem humano, tecnológico e organizacional. Posteriormente Jaber e Bonney (1999) também observaram que as curvas de aprendizagem não descreviam somente os progressos associados com a mudança na performance da mão de obra mas também descreviam os progressos obtidos com as mudanças

nos materiais, tecnologias de processo ou de produto e de gestão do nível do processo ao nível da empresa como um todo. Os autores também observaram que a melhoria na performance advinda da aprendizagem no nível organizacional é refletida no decréscimo do custo do produto e, portanto, representa uma vantagem para a organização tornando-a mais competitiva porém, como observou Grahame (2010) anos mais tarde, é importante lembrar que a curva de aprendizagem não é uma técnica de redução de custos.

Atualmente Attia, Megahed e Duquenne (2016) constataram que a melhoria de performance de uma organização ocorre na medida em que a empresa adquire experiência e a partir desta experiência se torna apta a construir ou acumular conhecimento, este que por sua vez é amplo e cobre todos os tópicos que podem contribuir com o aumento da performance organizacional.

No nível individual por sua vez, a teoria da curva de aprendizagem explica que à medida em que os trabalhadores executam determinada tarefa repetidamente, eles se familiarizam com ela e, portanto, se tornam mais rápidos em executá-la. Essa economia de tempo nas tarefas reflete-se na redução das horas necessárias para a fabricação do produto e por consequência na redução de seu custo unitário, o que pode ser observado por meio das curvas de aprendizagem, nas quais a quantidade de horas de trabalho ou custo unitário decrescem à medida em que a quantidade acumulada dos produtos aumenta (ARGOTE; EPPLE, 1990).

Estudos recentes como o de Badri et al. (2016), explicam como o fenômeno da aprendizagem no nível individual ocorre descrevendo que à medida em que algumas tarefas executadas repetidamente aumentam a experiência dos trabalhadores, eles irão lembrar todo o processo espontaneamente ou inesperadamente e o efeito disto é que esses trabalhadores irão encontrar soluções mais rápidas e adequadas para os problemas por meio de estratégias de economia de movimentos que encurtam o tempo de trabalho. Essa visão é complementada por Grahame (2010) ao afirmar que as curvas de aprendizagem representam um fenômeno humano que ocorre naturalmente uma vez que a aprendizagem ocorre porque as pessoas são engenhosas e aprendem a partir dos erros cometidos, além de estarem interessadas em encontrar maneiras de completar as tarefas com tempos menores no futuro.

No início da década de 90, os pesquisadores Adler e Clark (1991) observaram que mesmo melhorias relacionadas com alterações de projeto ocasionadas por mudanças de engenharia bem como alterações na tecnologia, nos processos, ferramentais entre outros fatores relacionados à aprendizagem no nível organizacional são na verdade fruto da

aprendizagem no nível individual pois, somente a partir da experiência adquirida pelas pessoas envolvidas nos processos que é possível enxergar e propor melhorias que refletem no declínio dos tempos e custos de fabricação. No entanto, a aprendizagem individual não ocorre somente com indivíduos envolvidos no processo de fabricação, mas também com aqueles que desempenham outras funções dentro de uma organização, pois como Thomassen (1998) constatou anos mais tarde, a aprendizagem no nível individual não ocasiona somente o aumento da eficiência do trabalhador no chão de fábrica, mas também em outras áreas que envolvem mão de obra tais como a manutenção, supervisão, gerência, etc.

A visão de que a aprendizagem no nível individual envolve pessoas de outros processos da empresa foi complementada no ano seguinte por Jaber e Bonney (1999) ao afirmarem que a curva de aprendizagem abrange mais do que o aumento da habilidade de um indivíduo pela repetição de uma simples operação. Para os autores, as curvas de aprendizagem descrevem um organismo complexo capturando o esforço coletivo de muitas pessoas estando algumas delas na linha de montagem diretamente no produto e outras em outros cargos, mas todas buscando realizar uma tarefa comum progressivamente melhor.

Dar-El (2000) também constatou que a aprendizagem humana é um tópico que afeta praticamente todos os esforços humanos já empreendidos, não importando qual seja a atividade. Para o autor, isso ocorre porque sempre que executamos uma tarefa seja ela qual for, recorremos à experiências e conhecimentos anteriores ou similares para nos ajudar a planejar e prever a melhor maneira de prosseguir com sua execução.

Wiersma (2007) reconhece a existência do fenômeno da aprendizagem nos dois níveis relacionando-os no tempo, pois para o autor, nas fases iniciais da curva de aprendizagem há um amplo espaço para re-projetar processos e cortar as folgas dos processos ineficientes e, neste momento, os fatores organizacionais que contribuem com a melhoria no desempenho da organização tais como alterações de processo, procedimentos, materiais, ferramentas, etc., tornam-se mais visíveis porém, em estágios posteriores essas oportunidades são reduzidas e consequentemente as melhorias nos processos ocorrem mais frequentemente a partir da aprendizagem autônoma dos empregados.

Além de sua aplicação no nível individual ou organizacional, também é possível observar que as curvas de aprendizagem podem ser utilizadas tanto na previsão do declínio das horas de trabalho necessárias para se produzir determinado produto quanto na previsão do declínio do custo unitário deste produto como foi constatado por Malysz e Pem (2013). Para os autores, a curva de aprendizagem pode ser aplicada não somente para prever o tempo de

um trabalho futuro, mas também o custo deste trabalho assumindo que os ciclos serão repetidos com as mesmas similaridades e condições de trabalho em termos de tecnologia, clima e trabalhadores, sem demoras ou grandes intervalos entre repetições.

## **2.2 Aplicações das curvas de aprendizagem**

Devido à capacidade de prever o tempo ou o custo que um determinado produto atingirá após um certo número de unidades produzidas, as curvas de aprendizagem tem encontrado espaço para inúmeras aplicações nas indústrias, auxiliando o planejamento da produção nos níveis operacional, tático e estratégico, além de serem adotadas por diversos tipos de organizações, por isso Stroieke, Fogliatto e Anzanello (2013) afirmaram que elas tem se mostrado uma ferramenta com várias utilidades na Engenharia de Produção desde que Wright desenvolveu o primeiro modelo de curva de aprendizagem em 1936.

No início da década de 50, Alchian (1950) observou que na indústria aeronáutica a curva de aprendizagem era utilizada como um dos instrumentos do planejamento, da programação e previsão sendo desenhada para expressar a relação entre a quantidade de mão de obra direta requerida para produzir uma determinada aeronave e o número de aeronaves produzidas associando a quantidade de horas de trabalho direto utilizada em sua produção com o número de aeronaves fabricadas no período.

Na década seguinte Keachie e Fontana (1966) introduziram a aplicação das curvas de aprendizagem no dimensionamento do lote econômico de produção enquanto Towill (1985) demonstrou que o aumento do desempenho ocasionado pelo tempo decorrido entre lotes fabricados é um fator significativo na melhoria dos tempos de produção e, portanto, dos custos incorridos.

Anos mais tarde Jaber e Bonney (1999) também aplicaram as curvas de aprendizagem na produção de lotes a partir da observação de que os modelos tradicionais de determinação do lote econômico de produção assumiam uma taxa de produção constantes, o que resulta em um número também constante de unidades produzidas em um determinado período, o que contraria a hipótese apresentada pela teoria da curva de aprendizagem e não representa a realidade do chão de fábrica.

Posteriormente Jaber e Bonney (2007) aplicaram a curva de aprendizagem-esquecimento desenvolvida por Jaber e Kher (2002) no dimensionamento do lote econômico observando a partir dos resultados obtidos que ignorar a estrutura motora e cognitiva de uma

tarefa pode resultar em políticas de tamanho de lote com erros de alta porcentagem nos custos previstos.

Grande parte das aplicações da curva de aprendizagem se encontra em setores industriais que possuem forte presença de capital humano em seus processos produtivos, como Benkard (2010) havia constatado quando afirmou que em indústrias com mão de obra intensiva como a aeronáutica e a marítima, por exemplo, a aprendizagem resulta principalmente dos trabalhadores se tornando mais eficientes nas tarefas que eles executam por meio de múltiplas repetições. No entanto, em meados da década de 60 Hirschmann (1964) verificou que até mesmo em uma indústria de produção contínua caracterizada por altos níveis de automação em seus processos e pouca dependência de capital humano, a curva de aprendizagem ainda é aplicável. Esse autor analisou um processo de refinamento de petróleo e observou que neste caso, a curva de aprendizagem existente poderia ser influenciada por modificações na organização e na tecnologia empregada por ela.

Anos mais tarde, Adler e Clark (1991) complementaram ao observar que mesmo processos altamente automatizados apresentam uma aprendizagem considerável e não somente processos com forte atuação de capital humano.

Na década de 90, Argote e Epple (1990) observaram que as curvas de aprendizagem foram documentadas em muitas organizações tanto na fabricação quanto no setor de serviços. Os autores identificaram diversas aplicações para as curvas de aprendizagem, tais como: formulação da estratégia de produção, preço e marketing do produto, treinamento, subcontratações e previsões do custo de competição, ilustrando a aplicação das curvas de aprendizagem em um nível mais elevado da organização assim como o fizeram Linton e Walsh (2004) ao ressaltarem que elas possuem grande potencial para auxiliar decisões acerca do projeto e seleção de tecnologias de processo, planejamento da capacidade e decisões de investimento.

Anos mais tarde Anzanello e Fogliatto (2007) observaram que o estudo da curva de aprendizagem tem despertado o interesse de setores industriais e acadêmicos nos últimos 80 anos e, embora a produção de aeronaves tenha sido o primeiro estudo de caso publicado a respeito das curvas de aprendizagem na indústria permanecendo até hoje entre os exemplos mais citados como observaram Benkard (2000) e Heng (2010). Moore et al. (2015) verificaram que o conceito de curvas de aprendizagem se difundiu e é aplicado atualmente em diferentes tipos de organizações tanto no setor público quanto no setor privado.

Benkard (2000) alegou que a aprendizagem também foi registrada em diversas outras indústrias como a de motores para aeronaves, ferramentas de máquinas, produtos de metal, energia nuclear, processos químicos, semicondutores e até mesmo a construção de navios enquanto Moore (2015) observou que da fabricação industrial até os *softwares* aviônicos o fenômeno da aprendizagem tem sido testemunhado.

Smunt (2013) complementa afirmando que estudos recentes tem demonstrado que as curvas de aprendizagem estão presentes em uma larga variedade de produtos, incluindo equipamentos eletrônicos, circuitos integrados e mesmo na montagem automotiva porém, outros exemplos de aplicações para as curvas de aprendizagem podem ser encontrados na literatura tais como o de Badri et al (2016), que aplicaram a curva de aprendizagem e de esquecimento em uma indústria do setor de vestuário ou o de Silayo, Migunga e Shemwetta (2014) que as aplicaram em um experimento com cortadores de árvores na Tanzania analisando trabalhadores experientes e inexperientes antes e depois de treinamentos e de intervalos na produção.

Malyuz e Pem (2013) aplicaram a curva de aprendizagem no setor da construção civil, especificamente na instalação de isolamentos de telhados enquanto Frey, Diawatti e Cakravastia (2011) a aplicaram na indústria automotiva em seis tipos de produtos diferentes pertencentes a duas linhas de montagem. Os autores avaliaram a curva de aprendizagem juntamente com dados de qualidade e complexidade dos produtos para identificar a relação entre eles.

Beneito, Engracia e Sanchis (2014) analisaram o papel da aprendizagem a partir da experiência em atividades de pesquisa e desenvolvimento observando que não apenas o número de inovações cresce conforme a experiência acumulada da empresa aumenta, mas também seu impacto no desempenho da organização como um todo mostrando que a aprendizagem contribui não somente com a obtenção de mais inovações, mas também com o aumento da qualidade das inovações implantadas.

Schoots, Kramer e van der Zwaan (2010) analisaram as curvas de aprendizagem na redução dos custos de fabricação de células de combustível tanto para fabricantes individuais quanto no mercado global observando que embora a taxa de aprendizagem utilizada seja tipicamente de 80% como foi adotada por Wright inicialmente, a taxa de aprendizagem demonstrada para o aprendizado na fabricação de células de combustível foi inferior, o que reforça a ideia de que as taxas de aprendizagem variam entre diferentes tipos de processo produtivo.



Linton e Walsh (2004) aplicaram a curva de aprendizagem em processos tecnológicos emergentes nos quais havia pouca aplicação das curvas de aprendizagem até então enquanto Nemet (2006) a aplicou na indústria de tecnologia energética, especificamente no setor de energia fotovoltaica para avaliar a influência da curva de aprendizagem na redução significativa de custos que essa indústria presenciou nos últimos anos. O autor verificou que embora a curva de aprendizagem esteja presente como um fator de influência no declínio dos custos que essa indústria presenciou, outros fatores foram mais expressivos nesta influência, tais como: demanda futura esperada, gerenciamento de riscos e pesquisa e desenvolvimento.

Shafer, Nembhard e Uzumeri (2001) estudaram a aplicação das curvas de aprendizagem em uma linha de montagem de rádios para automóveis investigando como os padrões de aprendizagem e esquecimento afetam o desempenho operacional da linha de montagem por meio de várias simulações.

Pendharkar e Subramanian (2007) investigaram a existência das curvas de aprendizagem no setor de desenvolvimento de *software* verificando que a relação entre a experiência dos programadores com a ferramenta "engenharia de software assistida por computador integrado" (ICASE) e seus esforços é inelástica quando a experiência é baixa.

Independentemente do setor industrial no qual a curva de aprendizagem é aplicada, várias centenas de pesquisas tem sido publicadas para estabelecer a aplicabilidade das curvas de aprendizagem, discutir sua utilização e entender sua teoria para atender a vários interesses conforme constataram Linton e Walsh (2004). Os autores ainda afirmaram que um grande número de extensões foi considerado na literatura para o modelo de curva de aprendizagem inicialmente proposto por Wright em 1936 com a finalidade de modelar sua relação com a gestão da qualidade, a entrada de produtos no mercado, a organização das linhas de montagem, entre outros, demonstrando que além de sua aplicabilidade em diferentes tipos de organizações, as curvas de aprendizagem também possuem diferentes propósitos para atender diversas áreas de interesse.

Stroieke, Fogliatto e Anzanello (2013) observaram que grande parte das pesquisas com curva de aprendizagem nas indústrias tem como objetivo primário ou secundário aumentar a qualidade da produção pela otimização do desempenho de seus processos e dos custos de seu processamento, além de melhor utilizar seus recursos, entre outros. Os autores revisaram a literatura identificando os principais tipos de aplicação para as curvas de aprendizagem, separando-os em monitoramento de custos, gerenciamento e otimização da produção, sequenciamento de tarefas com efeito da aprendizagem, atribuição de tarefas a

trabalhadores e balanceamento de linha, e dimensionamento do lote econômico com o efeito da aprendizagem, confirmando a ampla gama de aplicações das curvas de aprendizagem no setor industrial.

Nembhard e Uzumeri (2000) complementam afirmando que compreender o processo de aprendizagem é importante para uma série de pesquisas na área da produção, da definição dos tempos padrão à estimativa de custos com a mão de obra, além da otimização por meio de programas de treinamento.

Badiru (2012) observou que as curvas de aprendizagem são tradicionalmente utilizadas para o diagnóstico e propósitos de planejamento em operações já instaladas, exemplificando mais uma utilização da ferramenta entre tantas possíveis como por exemplo a de Plaza, Ngwenyama e Rohlf (2010), que estudaram o potencial das curvas de aprendizagem como um método para o planejamento e gerenciamento da implementação de projetos ERP (*Enterprise Resource Planning*).

Cadaval, Duarte e Paes (2013) observaram que até mesmo a taxa de aprendizagem, o principal parâmetro que compõe as curvas de aprendizagem, pode ser utilizada entre equipes e/ou turnos de trabalho como uma ferramenta de gestão e avaliação de desempenho. Os autores também verificaram a oportunidade que as curvas de aprendizagem tem de subsidiar o processo de planejamento, programação e controlar da produção por meio da definição dos índices de produtividade ao longo do tempo. Para eles, o planejamento da mão de obra deve ser fortemente impactado pelo aumento gradual da produtividade e, em decorrência disso, os modelos de curva de aprendizagem poderiam justificar a adoção de políticas de recursos humanos orientadas à manutenção da força de trabalho, às melhorias na produtividade e reduções de custos.

Anzanello e Fogliatto (2005) também estudaram a aplicação das curvas de aprendizagem no auxílio da melhor utilização dos recursos humanos em uma indústria do setor calçadista apresentando uma metodologia para utilizá-las como balizadoras para a alocação de modelos de produtos a equipes de trabalhadores visando minimizar as perdas no processo produtivo.

Em um nível mais operacional, Anzanello e Fogliatto (2007) observaram que as curvas de aprendizagem podem ser utilizadas nas estimativas de prazos para conclusão de tarefas ou no monitoramento dos custos associados à produção.

Smunt (2013) exemplifica a aplicação das curvas de aprendizagem em ambos os níveis afirmando que elas podem auxiliar o planejamento das operações de duas formas:

determinando a melhor alocação de esforços de engenharia e investimentos para a melhoria das operações e também promovendo maior acurácia às programações de custo à médio prazo.

Apesar de haver diferenças quanto ao nível no qual as curvas de aprendizagem são aplicadas ou quais propósitos as empresas utilizam para adotá-las, o que a maior parte dos autores relata é a importância de considerar o fenômeno da aprendizagem nas estimativas que suportam a tomada de decisão nas organizações para aumentar a acurácia dos dados analisados e conseqüentemente reduzir os riscos das decisões a serem tomadas. Essa importância foi enfatizada por Hirschmann (1964) ainda na década de 60 ao afirmar que além de ser utilizada como base para a projeção de custos, previsão de requerimento de mão de obra e programação da produção, as curvas de aprendizagem também são utilizadas na negociação de contratos multimilionários, o que ressalta ainda mais sua relevância para as organizações que a empregam e foi reforçada anos mais tarde por Grosse, Glock e Müller (2015) ao afirmarem que ainda que o conceito de curvas de aprendizagem no campo da economia da produção tenha sido introduzido há quase um século, ele ainda é de extrema importância para as empresas de manufatura uma vez que permite medir o desempenho da fabricação, auxiliar com a determinação dos tempos padrão, além de ser utilizada como ferramenta nas previsões ou mesmo ser aplicada juntamente com outras ferramentas de suporte à decisão.

### **2.3 Taxas e fatores de aprendizagem**

As diferentes equações utilizadas para construir as curvas de aprendizagem utilizam como parâmetro principal uma variável conhecida como taxa de aprendizagem, um valor percentual que é a taxa do decréscimo na quantidade de horas ou do custo associados à um determinado produto que ocorre a cada vez que a quantidade acumulada deste produto dobra ao longo do período, ou seja, à medida em que mais unidades são produzidas, as novas unidades passam a requerer somente uma porcentagem das horas de trabalho da unidade anterior. Argote (2012) chamou essa taxa de aprendizagem de termo de progresso, descrevendo-o como um percentual utilizado pelas indústrias para medir sua aprendizagem. Para a autora, a taxa de aprendizagem pode variar drasticamente entre tipos diferentes de produto e processos produtivos e devido à essa variação, enquanto algumas organizações evidenciam ganhos extraordinários de produtividade com a experiência adquirida ao longo do tempo, outras apresentam pouco ou nenhum ganho.

Linton e Walsh (2004) sugerem que essa diferença entre as taxas de aprendizagem pode ocorrer devido a problemas estruturais que fazem com que algumas organizações aprendam de forma ineficiente ou nem mesmo aprendam com a experiência adquirida ao longo dos anos, porém, como Yelle (1979) havia constatado anteriormente, a taxa de aprendizagem pode variar de organização para organização por se tratar de uma taxa que representa a aprendizagem no processo produtivo no qual ela é observada e cada organização possui um processo produtivo diferente.

Yelle (1979) ainda enfatizou que a estimativa da taxa de aprendizagem a ser utilizada é muito importante uma vez que a utilização de uma taxa que representa bem o fenômeno da aprendizagem no processo produtivo permite que os fabricantes planejem as atividades com maior precisão, pois fazem uso de dados de horas ou custos mais próximos do que deverá ocorrer no futuro. Para o autor, a falta de conhecimento acerca dos fatores que influenciam as taxas de aprendizagem na organização torna essa estimativa um desafio para as organizações fazendo com que estas utilizem muitas vezes dados históricos para obter esta estimativa.


No entanto, na década seguinte, os pesquisadores Dutton e Thomas (1984) afirmaram que a taxa de aprendizagem não deveria ser tratada como uma constante baseada no desempenho do passado sendo estimada a partir dele pois, para os autores, prever taxas de progresso futuras a partir de padrões históricos não é confiável dada a complexidade da dinâmica organizacional. Os autores sugerem que a taxa de aprendizagem seja tratada como uma variável dependente influenciada pelo comportamento da organização diante de uma dada configuração de fatores causais.

Os primeiros autores a estudarem a variação das taxas de aprendizagem entre processos distintos foram Dutton e Thomas (1984), que analisaram diversos estudos sobre curvas de aprendizagem coletando as taxas de aprendizagem que foram utilizadas por diferentes indústrias ao longo dos anos, num total de 108 taxas de aprendizagem observadas em 22 estudos de campo. Os autores verificaram que houve uma variação de 55% a 108% entre as taxas de aprendizagem que foram aplicadas pelas indústrias e construíram um histograma para representar a frequência com que cada intervalo de taxa de aprendizagem utilizada foi observado, como é possível visualizar na figura 2. As taxas de aprendizagem mais encontradas foram 81 e 82, valores que se aproximam do valor 80 descoberto por Wright em 1936.

Dutton e Thomas (1984) ainda complementam afirmando que análises mais detalhadas revelaram que as taxas de aprendizagem não variam somente entre indústrias, processos e

produtos diferentes, mas elas também assumem valores distintos entre indústrias, processos e produtos similares, o que foi reforçado anos mais tarde por Adler e Clark (1991) ao afirmarem que as variações nas taxas de aprendizagem foram encontradas na literatura até mesmo para produtos semelhantes e que essas variações não foram objeto de muita análise nos trabalhos desenvolvidos ao longo dos anos, o que demonstra uma lacuna no que se refere ao conhecimento das causas das variações das taxas de aprendizagem nas indústrias.

Figura 2 - Distribuição das taxas de aprendizagem observadas em 22 estudos de campo (N=108)



Fonte: Dutton e Thomas (1984, p. 5)

Heng (2010) também investigou o efeito das curvas de aprendizagem em 20 empresas de diferentes setores industriais em Singapura verificando que havia taxas de aprendizagem distintas entre elas. O autor então avaliou 11 empresas da Coreia do Norte e do Japão para comparar as taxas de aprendizagem observadas entre tipos similares de indústrias presentes em diferentes países para verificar se também havia diferença entre as taxas de aprendizagem observadas concluindo que mesmo em tipos similares de indústrias há uma variação na taxa de aprendizagem e as diferenças culturais entre os países pode ser um fator de influência para que isso ocorra.

Embora as taxas de aprendizagem sejam consideradas muito importantes para a aplicação das curvas de aprendizagem nas indústrias, as razões pelas quais essas taxas variam tanto entre processos diferentes ou similares foram pouco exploradas na literatura pois, como Dutton e Thomas (1984) constataram no início da década de 80, embora os engenheiros da indústria aeronáutica tenham explorado as causas da aprendizagem durante anos que

antecederam a Segunda Guerra Mundial, ainda existiam poucos estudos que apresentavam evidências à respeito das causas dessa variação.

Na década de 90, Badiru (1994) afirmou que existem numerosos fatores que podem influenciar quão rápido ou quão bem os trabalhadores poderão aprender a executar tarefas em um determinado período ainda que, conforme observaram Adler e Clark (1991), esses fatores tenham sido pouco explorados na literatura, o que também foi observado anos mais tarde por Benkard (2000) ao verificar que há na literatura uma escassez relacionada à aprendizagem e recentemente por Argote (2012) que afirmou que poucos autores conseguiram se aprofundar neste aspecto.

Um dos primeiros autores a mencionar a existência dos diversos fatores que influenciam a variação das taxas de aprendizagem entre as indústrias foi Hartley (1965) ao eleger alguns fatores que considerou como principais influentes do processo de aprendizagem nas organizações, sendo eles: as habilidades e eficiência dos trabalhadores, a complexidade do projeto, interrupções da produção, o controle, a inspeção e organização da fábrica como um todo e a eficiência e o grau da utilização de padrões e ferramentas.

Anos mais tarde Globerson e Levin (1987) apontaram a motivação para a melhoria como uma força condutora para iniciar mudanças que supostamente devem trazer as melhorias esperadas nos processos e conseqüentemente as reduções de tempos e custos associados, verificando que ela também é um fator que influencia a taxa de aprendizagem na organização. Essa visão foi complementada por Azizi, Zolfaghari e Liang (2010) ao apontarem a desmotivação como um fator de influência na variação da aprendizagem demonstrando que trabalhadores desmotivados apresentam queda em seu desempenho. Os autores desenvolveram um modelo de programação matemática para auxiliar com a rotatividade do trabalho com a finalidade de amenizar os impactos da desmotivação na queda da performance apresentada.

Em meados da década de 90, alguns autores também investigaram os fatores que influenciam as taxas de aprendizagem destacando-se entre eles Adler e Clark (1991), que realizaram um estudo de caso no qual observaram que dois fatores pouco mencionados na literatura também exerciam influência sobre a curva de aprendizagem, sendo eles as ordens de engenharia que compreendem as alterações no produto já em produção e o treinamento dos trabalhadores.

Ainda na década de 90, Thomassen (1998) verificou que as mudanças no *mix* de recursos como a substituição da mão de obra por automação também promovem uma base

com foco tecnológico para o efeito de aprendizagem, o qual também é influenciado pela padronização do produto e re-projeto que também contribuem com alterações nas taxas de aprendizagem.

No ano seguinte, Jaber e Bonney (1999) afirmaram que dentre os fatores que contribuem com a melhoria da performance da organização incluem-se uma utilização mais efetiva das ferramentas e máquinas, o aumento da familiaridade com as tarefas operacionais e com o ambiente de trabalho e um aumento na eficiência da própria gestão.

Alguns autores buscaram classificar os fatores que influenciam as taxas de aprendizagem para facilitar sua compreensão, como foi o caso de Dutton e Thomas (1984) que classificaram estes fatores em quatro categorias que variam em origem (exógenos ou endógenos) e em tipo (autônomo ou induzido). Já Globerson e Levin (1987) separaram os fatores entre pessoais, que compreendem mudanças na velocidade e economia de movimentos e organizacionais e os que referem-se à re-projetos de produtos e processos, programação da produção, controle de inventário, documentação do conhecimento pela organização e a própria gestão.

Ainda que os trabalhos relacionados às hipóteses de aprendizagem e fatores que influenciam as variações das taxas de aprendizagem sejam escassos na literatura quando comparados à trabalhos que aplicam as curvas de aprendizagem, a partir do ano 2000 diversos autores buscaram compreender esses fatores alcançando resultados significativos como foi o caso de Wiersma (2007) que ao estudar os fatores que influenciavam a variação da taxa de aprendizagem nas unidades da *Royal Dutch Mail Company* dispersas em 27 regiões geográficas, identificou dois fatores que merecem destaque: o primeiro mostra que em processos maduros a inclusão de trabalhadores temporários aumenta a taxa de aprendizagem possivelmente porque um grupo mais diversificado está mais apto a recombinar o conhecimento antigo com o novo uma vez que trabalhadores temporários estão menos familiarizados com as normas da organização e podem tentar fazer uso do conhecimento já estabelecido por trabalhadores antigos para gerar novos conhecimentos no processo de fabricação enquanto o segundo demonstra que unidades com maior *mix* de produtos e conseqüentemente uma experiência mais diversificada possuem uma taxa de aprendizagem maior, o que pode ocorrer pela possibilidade do aprendizado de um tipo de produto ser transferido para outros tipos ou porque empregados que trabalham com um *mix* maior de produto possuem um entendimento cognitivo maior do contexto das tarefas e, portanto, estão mais aptos a aprender.



Frey, Diawati e Cakravastia (2011) incluíram a complexidade do produto, o takt time da produção, obstáculos no processo, o ciclo produtivo e mesmo o esquecimento entre os fatores já conhecidos.

Para Plaza, Ngwenyama e Rohlf (2010) que observaram a aplicação das curvas de aprendizagem na implementação de projetos de TI, entre os fatores que afetam a performance do time incluem-se o próprio conhecimento já existente dos membros do time, a prática e a experiência adquiridas com a implementação de outros projetos.

Wiersma (2007) ainda afirma que um número ilimitado de fatores podem afetar a variação na taxa de aprendizagem como ambientes voláteis, integração vertical, o tipo de tecnologia de produção, etc. enquanto Benkard (2000) conclui que a natureza particular da operação por si só já faz com que a aprendizagem tome formas diferentes.

Heng (2010) também listou os fatores que influenciam a aprendizagem, sendo eles: a experiência que os trabalhadores adquirem enquanto repetem a tarefa, a aprendizagem dos próprios gestores destes trabalhadores, melhorias no fluxo dos materiais, utilização de ferramentas mais ágeis e melhor organização da planta, além dos próprios fornecedores de materiais que também podem aprender com a prática e fabricar com mais eficiência repassando parte da vantagem obtida para a organização contratante através de custos menores de material. Para o autor, até mesmo a engenharia de manufatura adquire aprendizagem e por esse motivo os engenheiros que podem ter tomado mais cuidado com o projeto do produto no início utilizando tolerâncias mais rigorosas no projeto do produto podem por meio da experiência adquirida aumentar as tolerâncias no projeto, o que reduz a quantidade de paradas por rejeições de itens fora do especificado e retrabalhos.

Para Argote (2012), além de uma estimativa mais precisa da taxa de aprendizagem, compreender os fatores que a influenciam pode trazer diversos outros benefícios para as organizações que podem fazer uso desta compreensão para elaborar estratégias que façam com que o processo de aprendizagem seja alto, ou seja, que o declínio nas horas requeridas para a produção de determinado produto seja grande à medida que a fabricação deste produto avança e não se perca com o tempo, daí a importância de se entender os contrastes entre as organizações que evidenciam pouco ou nenhum aumento de produtividade com a experiência adquirida e aquelas que demonstram altas taxas de aprendizagem em seus processos.

Badiru (2012) complementa afirmando que uma melhor compreensão dos perfis das curvas de aprendizagem se faz fundamental, pois, a partir desta compreensão é possível auxiliar o desenvolvimento de programas de intervenção no esquecimento, evitando que o

aprendizado adquirido se perca com o tempo contribuindo diretamente com a sustentabilidade da aprendizagem na organização.

Para Wiersma (2007), observar os fatores que explicam as variações nas taxas de aprendizagem pode apontar diversas estratégias para os gerentes de produção utilizarem para manter uma curva de aprendizagem positiva em produções maduras, além de auxiliá-los no projeto de processos de trabalho melhores.

## **2.4 O fator esquecimento nas curvas de aprendizagem**

De acordo com Jaber e Guiffrida (2004), no modelo de curva de aprendizagem proposto por Wright em 1936 está implícita a afirmação de que o conhecimento adquirido não deprecia porém, vários estudos empíricos refutaram esta afirmação.

A depreciação do conhecimento é chamada na literatura de esquecimento e, conforme afirmou Badiru (1994), enquanto a aprendizagem tende a aumentar a performance na produção, o esquecimento tende a reduzi-la.


Segundo Hockenberry (2008), as organizações se movem ao longo das curvas de aprendizagem até que intervalos na produção ou mudanças na natureza das tarefas produtivas causem reduções temporárias na produtividade, reduções essas que Jaber e Guiffrida (2004) chamaram de depreciação do conhecimento ou esquecimento, representadas pela queda de performance da produção que ocorre sempre que sessões de aprendizagem são separadas por intervalos na produção. Malyusz e Pem (2013) complementam afirmando que sempre que há intervalos na produção, ocorre um aumento na quantidade de horas de trabalho e custos associados a um determinado produto.

Silayio, Migunga e Shemwetta (2014) também acreditam que assim como a aprendizagem aumenta com a experiência, o esquecimento aparenta aumentar como uma função do intervalo na execução das tarefas, o que significa que quando ocorre uma interrupção na produção de determinado produto, a quantidade de horas necessárias para produzi-lo tende a aumentar enquanto não houver produção, proporcionalmente ao tamanho deste intervalo e, portanto, quando ocorre a retomada do processo produtivo, a quantidade de horas necessárias para produzir o primeiro produto após o intervalo é superior a quantidade de horas que foram necessárias para a produção do último produto fabricado antes da interrupção no processo produtivo ocorrer (BADIRU, 1994).

A relação aprendizagem-esquecimento-aprendizagem foi ilustrada por Jaber e Bonney (1996) e pode ser observada na figura 3. Nela, é possível verificar que o tempo inicial de

produção de um determinado produto representado na figura por “ $T_1$ ” é reduzido à medida em que mais unidades são produzidas até que no momento representado pela letra “ $q$ ” no eixo X ocorre a interrupção da produção fazendo com que o tempo volte a crescer de acordo com a proporção de unidades que seriam produzidas caso não houvesse a interrupção da produção naquele momento. A partir do instante representado no eixo X por “ $q+R$ ”, a produção é retomada e a aprendizagem passa a ocorrer novamente fazendo com que o tempo necessário para produzir o produto volte à decrescer à medida em que mais unidades são produzidas.

Figura 3 - O declínio e aumento nas horas de trabalho devido à aprendizagem e ao esquecimento



Fonte: Jaber e Bonney (1996, p. 163)

Segundo Hockenberry (2008), a ideia da depreciação de capital humano é baseada na falha em reter habilidades ou conhecimento previamente acumulados por meio da educação ou experiência e que o esquecimento enquanto apelidado de organizacional, é na verdade parcialmente baseado no esquecimento individual dos trabalhadores, sendo normalmente visto como um fator negativo sob o aspecto da aprendizagem.

Remor et al. (2010) fizeram uma importante colocação ao observarem que o esquecimento é necessário para a aprendizagem tanto quanto pode ser prejudicial, pois é necessário que ele ocorra para dar lugar aos conhecimentos novos, evitar que conhecimentos incompatíveis entre o indivíduo e a organização sejam incorporados na memória e também

para a formação de uma memória seletivamente útil e dirigida para os objetivos da organização. Para os autores este esquecimento é benéfico e necessário para que processos de mudanças e avanços ocorram.

Ainda que haja benefícios para a aprendizagem relacionados ao esquecimento, a literatura relacionada ao tema focou nos malefícios causados pelo esquecimento ou depreciação do aprendizado que ocorre diante de intervalos de produção representados pela queda da produtividade ou aumento dos custos e ciclos de fabricação porém, independentemente do quão necessário ou prejudicial seja o esquecimento sob a ótica da aprendizagem, é fato que ele deve ser compreendido e considerado para tornar as previsões das curvas de aprendizagem ainda mais precisas pois, como Nembhard e Osothsilp (2002) afirmam, considerar os efeitos da aprendizagem e do esquecimento na medição da produtividade deveria ajudar a melhorar a acurácia do planejamento da produção e das estimativas de produtividade uma vez que tornam os dados mais realistas dado que os efeitos da aprendizagem e do esquecimento já foram comprovados.

Grande parte dos autores que estudaram o tema reconhece a existência do esquecimento e sua influência no declínio da produtividade afirmando que é necessário modelá-lo assim como é feito com a aprendizagem pois, desta forma, é possível se obter previsões de queda na performance, elaborando estratégias para reduzir as perdas diante de intervalos de produção (BADIRU, 1994; GLOBERSON, LEVIN E SHTUB, 1989; JABER E BONNEY, 1996, 1997;).

Em meados da década de 90, Badiru (1994) reforçou a importância de se modelar o fenômeno do esquecimento declarando que a inclusão de um modelo de esquecimento nas previsões efetuadas pela organização cria uma representação realista das operações de fabricação que são submetidas à interrupções no processo de aprendizagem, o que não é tão incomum, principalmente na fabricação de aeronaves no setor de Defesa e Segurança uma vez que existem intervalos nos lotes que são fornecidos para diferentes governos na maioria dos casos.

Devido à importância de se modelar também o fenômeno do esquecimento assim como ocorreu com o fenômeno da aprendizagem, alguns modelos de curvas foram propostos na literatura para descrever o declínio na produtividade e consequente aumento nas horas de trabalho ocasionado por ele, sendo o modelo proposto por Globerson, Levin e Shtub (1989) um dos mais conhecidos. No entanto, ainda existem lacunas que precisam ser exploradas quanto à questão do esquecimento e como ele afeta a organização pois, como afirmam Jaber e

Bonney (1999), ainda que haja uma concordância quase unânime por cientistas e praticantes na forma da curva de aprendizagem apresentada por Wright em 1936, um entendimento mais completo do comportamento e dos fatores que afetam o processo de esquecimento ainda não foi desenvolvido.

Anos mais tarde, Silayio, Migunga e Shemwetta (2014) afirmam que área da psicologia a questão do esquecimento tem atraído a atenção de psicólogos já há algum tempo ainda que voltada mais para a questão do conhecimento individual, daí a importância de se explorar o fenômeno na indústria pois, como afirmou Badiru (1994) anteriormente, enquanto a extensiva literatura escreve sobre aprendizagem, nenhum estudo rigoroso do efeito do esquecimento pode ser encontrado na literatura enquanto Benkard (2000) e Moore (2015) afirmam que embora o esquecimento organizacional esteja se tornando mais aceito entre os pesquisadores, sua aplicação na manufatura ainda é escassa.

Para Globerson e Levin (1987), uma das razões pela qual o esquecimento não é muito estudado provavelmente é devido às dificuldades práticas de se obter dados sobre o nível do esquecimento como uma função do tempo.

Anos mais tarde, Remor et al. (2010) também constataram que o esquecimento foi pouco explorado na literatura. Em seu estudo, os autores pesquisaram diversas bases de dados e localizaram apenas um artigo publicado no Brasil sobre o efeito do esquecimento nas curvas de aprendizagem. Buscando na literatura estrangeira os autores observaram que existe uma quantidade maior de trabalhos sobre o esquecimento publicados, no entanto, se comparado a quantidade de trabalhos encontrados sobre curvas de aprendizagem em geral, a quantidade de pesquisas relacionadas às aplicações das curvas de aprendizagem com esquecimento ainda é menor.

Jaber e Bonney (1996) já haviam constatado que poucos trabalhos à respeito do fenômeno do esquecimento nas curvas de aprendizagem foram publicados contudo, Jaber e Sikstrom (2004) mencionam que alguns modelos matemáticos de esquecimento empíricos, experimentais e teóricos foram desenvolvidos ao longo dos anos, ainda que sem um acordo unânime entre os pesquisadores e praticantes quanto à forma como o esquecimento ocorre e como dimensiona-lo.

Em meados da década de 70, Carlson e Rowe (1976) desenvolveram um modelo de aprendizagem-esquecimento-aprendizagem no qual o esquecimento é modelado similarmente à aprendizagem porém, anos mais tarde Bailey (1989) afirmou que a taxa de esquecimento

deveria ser diferente da taxa de aprendizagem uma vez que as pessoas aprendem e esquecem de formas distintas.

No final da década de 80, Globerson, Levin e Shtub (1989) realizaram um experimento que como principal resultado trouxe a indicação de que o esquecimento é uma função do intervalo e do nível de experiência adquirida antes dele. Os autores propuseram uma curva do esquecimento como um modelo adequado para descrever essa relação entre a extensão do intervalo, o tempo de execução da tarefa antes do intervalo e o grau de esquecimento.

Posteriormente, outros trabalhos também buscaram desenvolver modelos para o esquecimento como foi o caso de Martinez e Revilla (2015) que analisaram trabalhadores de contratações temporárias observando que mesmo após intervalos de produção em uma determinada atividade, os trabalhadores que permaneceram desempenhando atividades similares àquelas executadas antes do intervalo, especificamente com no mínimo 40% de semelhança, continuaram apresentando tempos decrescentes na execução das tarefas, o que pode sinalizar uma importante oportunidade para as empresas que trabalham sob regime temporário em diferentes plantas traçarem uma estratégia diferenciada uma vez que estas podem encontrar maneiras de retardar o processo de esquecimento a partir de atividades similares em outros locais durante intervalos de produção em determinadas plantas.

Compreender o esquecimento e os fatores que o influenciam se tornou tão importante quanto compreender a aprendizagem e os fatores que provocam variações nas taxas de aprendizagem observadas, ao menos em cenários nos quais existem interrupções na produção, pois, somente assim previsões mais acuradas podem ser efetuadas suportando melhor a tomada de decisão quanto à alocação dos recursos, a distribuição das tarefas e a programação da produção, entre outros aspectos.

## **2.5 Modelos de curvas de aprendizagem**

Ao longo dos anos, numerosos modelos de curvas de aprendizagem foram desenvolvidos para representar o fenômeno da aprendizagem nas organizações e, conforme Anzanello e Fogliatto (2007) observaram, esses modelos são constituídos por funções matemáticas de diversas complexidades sendo classificados entre modelos de curvas univariadas e multivariadas, destacando-se entre os modelos de curvas univariadas os modelos potenciais, exponenciais e hiperbólicos.

Anzanello e Fogliatto (2005) afirmam que o modelo potencial desenvolvido por Wright em 1936 constitui-se na curva de aprendizagem mais difundida devido à sua estrutura simples e boa capacidade de aderência aos dados empíricos, o que havia sido observado anos antes por Badiru (1994) ao afirmar que o modelo log-linear desenvolvido por Wright foi reconhecido como o modelo básico para a maioria das análises de produtividade na fabricação.

Para Moore et al. (2015), embora o modelo tenha sido alterado ao longo dos anos para se encaixar em diferentes aplicações assim como observaram Anzanello e Fogliatto (2007) ao afirmarem que o extensões do modelo de Wright foram desenvolvidas para cenários específicos geralmente com a adição de um ou mais parâmetros, muitas indústrias ainda utilizam o modelo de Wright como padrão.

Linton e Walsh (2004) enfatizam que é importante reconhecer que algumas ou todas as diferenças nos modelos propostos podem ser um resultado das diferenças na eficiência da aprendizagem nas organizações, além dos diversos outros fatores que a influênciam e, portanto, cabe a cada organização selecionar o modelo que melhor se adeque ao seu perfil de aprendizagem.

Moore (2015) e Moore et al. (2015) também ressaltaram a importância de se adotar um modelo adequado para aumentar a precisão da curva de aprendizagem nas organizações. Os autores compararam o modelo de Wright com outros modelos propostos na literatura por meio de um teste estatístico conhecido como Dunnett com a finalidade de avaliar se um ou mais modelos seriam mais adequados que o modelo de Wright para representar o fenômeno de aprendizagem no setor de Defesa americano.

Grosse, Glock e Müller (2015) efetuaram uma revisão da literatura apresentando os modelos mais frequentemente utilizados e, dentre os modelos potenciais, destacam-se os modelos de Wright, Stanford-B, DeJong e Curva-S, que são apresentados a seguir. Outros modelos potenciais, exponenciais e hiperbólicos também foram compilados pelos autores e uma amostra dessa compilação pode ser visualizada no anexo A..

### **2.5.1 Modelo de Wright**

Wright (1936) observou que as horas necessárias para produzir uma aeronave decresciam à medida que mais aeronaves eram produzidas porém, ele foi além, identificando uma taxa de aprendizagem de 80% ao verificar que as horas necessárias para produzir um aeronave decresciam 20% cada vez que a quantidade acumulada de aeronaves produzidas era

dobrada. O modelo de Wright foi desenvolvido na década de 30 e permanece como o modelo mais aplicado devido à sua simplicidade, como é possível verificar na equação (1), representada abaixo.

$$Tx = T_1 x^b, \quad (1)$$

Onde:

$Tx$  denota a quantidade de horas referente à unidade  $x$

$T_1$  denota as horas necessárias para produzir a primeira unidade

$x$  denota o número da unidade acumulada

$b = \log R / \log 2$ , sendo  $R$  a taxa de aprendizagem do trabalhador medida percentualmente (decimal)

Embora muito aplicado, o modelo de Wright também sofreu algumas críticas como por exemplo, a efetuada por Dar-El (2000) ao afirmar que uma das desvantagens do modelo de Wright é que não há um momento em que o aprendizado se estabiliza de modo que o tempo necessário para efetuar uma atividade tende à zero se for aplicado em larga escala. No entanto, para contornar este problema, aderiu-se ao efeito platô, observado primeiramente por Conway e Schultz (1959), onde adiciona-se uma constante " $C$ " ao modelo de Wright para que ele tenda à um valor específico ao longo da curva, como é possível verificar na equação (2).

$$Tx = C + T_1 x^b, \quad (2)$$

Onde:

$Tx$  denota a quantidade de horas referente à unidade  $x$

$C$  denota a quantidade de horas necessárias para a produção quando a aprendizagem cessa

$T_1$  denota as horas necessárias para produzir a primeira unidade

$x$  denota o número da unidade acumulada

$b = \log R / \log 2$ , sendo  $R$  a taxa de aprendizagem do trabalhador medida percentualmente (decimal)

Outra crítica ao modelo de Wright refere-se à utilização do número de unidades produzidas como a única variável independente para o monitoramento do progresso de trabalhadores em uma tarefa e isso tem gerado questionamentos quanto à eficiência do modelo de aprendizagem conforme observado por Anzanello e Fogliatto (2007). Isso ocorre



porque diante de inúmeros outros fatores que exercem influência sobre a aprendizagem considerar apenas o volume acumulado da produção não parece ser razoável em aplicações que precisam que outras variáveis sejam consideradas para modelar a aprendizagem no chão de fábrica, como por exemplo a existência da experiência prévia dos trabalhadores ou o grau de automação dos processos e para sanar este problema modelos distintos foram desenvolvidos ao longo dos anos, como os modelos de Stanford-B, DeJong e o modelo de Curva-S, todos apresentados na sequência.

### 2.5.2 Modelo Stanford-B

O modelo Stanford-B, representado pela equação (3), considera que a experiência prévia dos trabalhadores influencia o comportamento da curva de aprendizagem, pois, quando existe experiência prévia é mais fácil aprender e, portanto, a quantidade de horas necessárias na fabricação decrescem mais rapidamente do que quando não há experiência prévia e por isso ela se tornou como um parâmetro na hora de projetar a curva de aprendizagem através da utilização de uma constante representada pela letra B que pode variar de 0 a 10 de acordo com a quantidade de ciclos que foram executados antes, seja com a mesma tarefa no passado ou em tipos similares como por exemplo a fabricação de protótipos, muito comum antes da fabricação em série, principalmente na indústria aeronáutica. A adição deste parâmetro pressupõe que experiências prévias contribuem com um declínio maior da curva utilizando como premissa a existência de conhecimento adquirido anteriormente.

$$Tx = T_1(x + B)^b, \quad (3)$$

Onde:

$Tx$  denota a quantidade de horas referente à unidade  $x$

$T_1$  denota as horas necessárias para produzir a primeira unidade

$x$  denota o número da unidade acumulada

$B$  denota a unidade de experiência equivalente (constante). Este valor varia de 0 à 10 e é definido de acordo com a quantidade de produtos similares que foram fabricados antes.

$b = \log R / \log 2$ , sendo  $R$  a taxa de aprendizagem do trabalhador medida percentualmente (decimal)

Observe que se o parâmetro B for 0, ou seja, não há existência de conhecimento prévio dos operadores, o modelo iguala-se ao proposto por Wright.

### 2.5.3 Modelo DeJong

O modelo DeJong, representado pela equação (4), também é uma derivação do modelo de Wright, porém, o modelo DeJong considera o grau de automação presente no processo produtivo incluindo um fator de incompressibilidade representado pela letra M que pode variar de 0 à 1 sendo 0 um processo no qual não há nenhum grau de automação e 1 um processo altamente automatizado. Aqui também é possível observar que quando M assume o valor 0 (zero), o modelo iguala-se ao de Wright.

$$Tx = T_1[M + (1 - M)x^b], \quad (4)$$

Onde:

Tx denota a quantidade de horas referente à unidade x

$T_1$  denota as horas necessárias para produzir a primeira unidade

M denota o fator de incompressibilidade (constante) que representa o nível de automação do processo produtivo, podendo variar de 0 (nenhum grau de automação) à 1 (altamente automatizado)

x denota o número da unidade acumulada

$b = \log R / \log 2$ , sendo R a taxa de aprendizagem do trabalhador medida percentualmente (decimal)

### 2.5.4 Modelo Curva-S

O modelo Curva-S combina as características de ambos os modelos, Stanford-B e DeJong utilizando as variáveis B e M, como é possível observa na equação 5.

$$Tx = T_1 + M(x + B)^b, \quad (5)$$

Onde:

Tx denota a quantidade de horas referente à unidade x

$T_1$  denota as horas necessárias para produzir a primeira unidade

M denota o fator de incompressibilidade (constante) que representa o nível de automação do processo produtivo, podendo variar de 0 (nenhum grau de automação) à 1 (altamente automatizado)

$x$  denota o número da unidade acumulada


$B$  denota a unidade de experiência equivalente (constante). Este valor varia de 0 à 10 e é definido de acordo com a quantidade de produtos similares que foram fabricados antes.

$b = \log R / \log 2$ , sendo  $R$  a taxa de aprendizagem do trabalhador medida percentualmente (decimal)

Segundo Anzanello e Fogliatto (2007), o modelo de Curva-S contempla operações que necessitam da intervenção de máquinas e cuja análise do desempenho nas primeiras unidades assume importância para a descrição do processo.

Uma comparação gráfica dos principais modelos potenciais descritos anteriormente foi apresentada por Anzanello e Fogliatto (2007) e pode ser visualizada na figura 4.

Figura 4 - Comparação gráfica dos principais modelos potenciais



Fonte: Anzanello e Fogliatto (2007, p.113)

Na figura acima é possível observar que em escala logarítmica o modelo de curva de aprendizagem de Wright é uma reta e quando o efeito platô é considerado, a adição de uma constante ao modelo faz com que o declínio do tempo de produção cesse em determinada quantidade de unidades produzidas, o que significa que a partir dela não há mais ganhos decorrentes da aprendizagem.

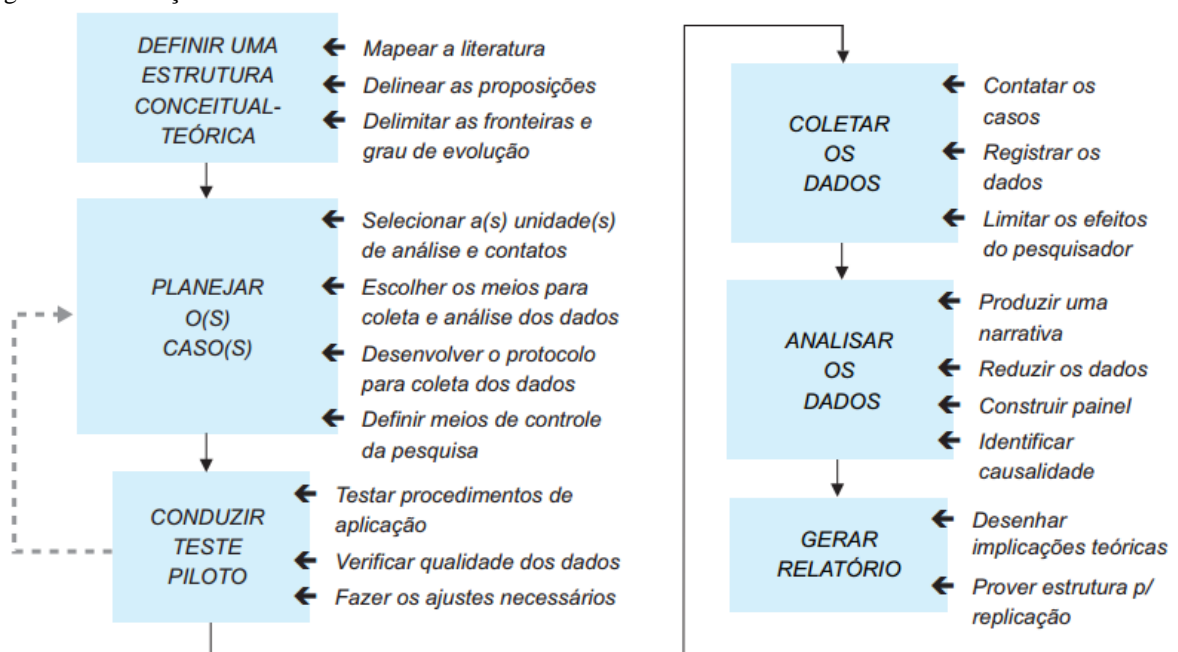
### 3 MÉTODO DA PESQUISA

Esta pesquisa foi realizada por meio de um estudo de caso que, segundo Yin (2001), permite uma investigação para se preservar as características holísticas e significativas dos eventos da vida real - tais como ciclos de vida individuais, processos organizacionais e administrativos, entre outros.

Para Ventura (2007), o estudo de caso como modalidade de pesquisa é entendido como uma metodologia ou como a escolha de um objeto de estudo definido pelo interesse em casos individuais visando a investigação de um caso específico, bem delimitado, contextualizado em tempo e lugar para que se possa realizar uma busca circunstanciada de informações.

Miguel (2007) afirma que o estudo de caso pode ser compreendido como um estudo de natureza empírica que investiga um determinado fenômeno, geralmente contemporâneo, dentro de um contexto real de vida, quando as fronteiras entre o fenômeno e o contexto em que ele se insere não são claramente definidas. O autor ainda propõe um modelo para a condução do estudo de caso que pode ser observado na figura 5.

Figura 5 – Condução do estudo de caso



Fonte: Miguel (2007, p.221)

Seguindo o modelo de condução de pesquisa proposto por Miguel (2007), o estudo foi realizado da seguinte forma:

- Etapa 1: a primeira etapa da pesquisa contemplou o mapeamento da literatura por meio da busca por trabalhos relacionados às curvas de aprendizagem em diferentes bases de dados. Após este levantamento, foi necessário separar os trabalhos relacionados à aplicação de curvas de aprendizagem no setor industrial dos trabalhos com a aplicação das curvas em outros setores como o da saúde, por exemplo, onde também existe uma vasta aplicação das curvas de aprendizagem.
- Etapa 2: após o mapeamento da literatura, foi efetuado o planejamento da pesquisa a partir da escolha da área de negócio da empresa, de sua unidade e por fim do produto que seria investigado, bem como a escolha do modelos de curvas de aprendizagem Stanford-B, DeJong e Curva-S que seriam aplicados para efetuar a comparação com o modelo de Wright utilizado atualmente pela empresa. Nesta etapa também foram determinados os métodos de coleta e análise dos dados, o que dividiu a aplicação em 2 partes, pois na primeira parte os parâmetros utilizados pelos modelos foram determinados com base na literatura e na segunda parte os parâmetros foram inferidos através do estimadores Bayesianos. Também foram determinados quais seriam os instrumentos de coleta, neste caso documentos da própria organização com dados históricos da quantidade de horas de produção do produto selecionado e também dados de horas necessárias para produzir as próximas unidades do produto fornecidos por aplicações dos modelos efetuadas com os *softwares* MS Excel, OpenBugs e Minitab. Essa aplicações serão detalhadas na seção subsequente. Como Miguel (2007) constatou, a realização de um teste-piloto não é uma prática comum em estudo de caso e, nesta pesquisa, optou-se por não efetuá-lo uma vez que não seriam utilizadas entrevistas ou aplicações de questionários, passando-se para a etapa seguinte.
- Etapa 3: os dados históricos do produto escolhido foram coletados na base de dados da organização e um teste de normalidade foi aplicado para verificar se era uma distribuição normal, sendo em seguida transformados para que fosse possível construir um gráfico em escala logarítmica e se obter a taxa de aprendizagem a partir da inclinação da reta. Com a taxa de aprendizagem obtida, os dados para a comparação foram gerados por computador através da aplicação dos modelos de curvas de aprendizagem selecionados, sendo eles: Wright, Stanford-B, DeJong e Curva-S.
- Etapa 4: nesta etapa os dados coletados foram analisados e a comparação entre os valores gerados pelos modelos selecionados com os dados coletados nos documentos históricos da organização foi efetuada com a finalidade de verificar qual modelo

melhor representou a realidade em questão. A comparação entre os modelos na primeira parte da aplicação foi efetuada através do teste Dunnett enquanto na segunda parte da aplicação efetuou-se uma comparação gráfica com os valores gerados pelos estimadores bayesianos.

- Etapa 5: o relatório resultante da análise dos dados na etapa anterior foi gerado e as principais conclusões foram levantadas com base nos resultados obtidos. Essas conclusões são apresentadas na seção 5.

## 4 ESTUDO DE CASO

O estudo de caso foi desenvolvido em uma empresa que atua no setor aeronáutico há mais de 45 anos sendo uma das maiores do mundo no setor, além de ter presença em diversos países e contar com cerca de 19 mil funcionários. No setor de Defesa e Segurança, fabrica e moderniza diversos tipos de aeronave atendendo mais de 40 governos.

A aplicação foi desenvolvida em duas fases que serão descritas a seguir.

### 4.1 Fase 1 – Aplicação dos modelos com parâmetros pré-estabelecidos

A primeira fase consiste em executar a análise dos modelos de Stanford-B, DeJong e Curva-S utilizando-se parâmetros “B” e “M” com valores pré-estabelecidos com base na literatura, sendo 1 o valor de B, pois é baixa a experiência prévia dos trabalhadores e M variou de 0,05 a 0,20 pois o nível de automatização do processo produtivo não é alto, verificando os desvios apresentados por cada modelo em relação ao dados históricos de hora-homem da aeronave escolhida obtendo-se a média do erro absoluto de cada modelo e comparando os valores obtidos com a média do erro absoluto apresentado pelo modelo de Wright através do teste Dunnett que efetua a comparação de valores utilizando um valor como referência, como foi realizado anteriormente por Moore (2015) e Moore et al. (2015).

O teste Dunnett foi selecionado porque permite efetuar a comparação de diversos valores com um valor específico denominado controle e, neste caso, o controle será o valor da média do erro absoluto apresentada pelo modelo de Wright que é o modelo utilizado atualmente pela organização onde este estudo de caso foi desenvolvido. Esta etapa consiste, portanto, em 5 passos detalhados a seguir:

- Passo 1: Definição dos parâmetros B e M para utilização nos modelos Stanford-B, DeJong e Curva-S para aplicação e geração dos dados de hora-homem necessários para produzir cada unidade da aeronave escolhida, sendo 1 o valor de B, pois há baixa experiência prévia dos trabalhadores e M variando de 0,05 a 0,20 dado que o nível de automatização do processo produtivo não é alto;
- Passo 2: Coleta dos dados históricos de hora-homem da aeronave escolhida e verificação da normalidade dos mesmos para possível conversão dos valores para a escala logarítmica e construção do gráfico no qual será aplicada a regressão linear para obter-se o valor da constante "b" que corresponde à inclinação da reta utilizada

pelos modelos. Através desta inclinação se obtém a taxa de aprendizagem que será utilizada nos modelos selecionados;

- Passo 3: Aplicação dos modelos de curva de aprendizagem com os parâmetros definidos na etapa 1 e a taxa de aprendizagem obtida na etapa anterior para gerar a previsão pelos modelos dos valores de hora-homem necessários para a produção de cada número de série;
- Passo 4: Cálculo do erro absoluto subtraindo-se o valor real do valor previsto por cada modelo e então multiplicando os valores negativos por (-1) para garantir que os valores negativos não anulem os valores positivos no cálculo da média dos erros. Após esta operação, será efetuada a divisão do erro absoluto obtido pelo valor real dos dados para se obter o percentual de erro absoluto e então será efetuado o cálculo da MAPE (*mean absolute percentual error*) ou média do percentual do erro absoluto, em português, para cada um dos modelos. Um exemplo desta etapa utilizando o modelo de Wright pode ser conferido na tabela 1, no entanto, os valores não correspondem aos reais à fim de manter a confidencialidade dos dados;
- Passo 5: Comparação da MAPE entre os modelos Stanford-B, DeJong e Curva-S com o valor do modelo de Wright (variável de controle na comparação) por meio do teste de Dunnett e verificação dos modelos que apresentaram uma MAPE significativamente menor em relação ao modelo de Wright sendo portanto mais precisos que ele na previsão dos dados neste caso.

Tabela 1 – Exemplo da etapa 4 utilizando o modelo de Wright.

Qtd. Acum.	Valor real	Valor previsto	Erro	Erro absoluto	% Erro absoluto
1	11242,10	-			
2	11718,46	10933,17	785,29	785,29	0,067013
3	11131,60	10756,41	375,19	375,19	0,033705
4	10748,20	10632,73	115,47	115,47	0,010744
5	11364,72	10537,77	826,95	826,95	0,072764
6	13257,20	10460,82	2796,38	2796,38	0,210933
7	11135,90	10396,20	739,70	739,70	0,066425
8	11234,66	10340,54	894,12	894,12	0,079586
9	9020,36	10291,69	-1271,33	1271,33	0,140941
10	8514,48	10248,20	-1733,72	1733,72	0,203620
11	8959,46	10209,01	-1249,55	1249,55	0,139467
12	7636,58	10173,36	-2536,78	2536,78	0,332188
13	6792,46	10140,68	-3348,22	3348,22	0,492931
14	6708,24	10110,51	-3402,27	3402,27	0,507178
15	7083,86	10082,51	-2998,65	2998,65	0,423307



16	6595,70	10056,38	-3460,68	3460,68	0,524688
17	7107,06	10031,90	-2924,84	2924,84	0,411541
18	7025,10	10008,88	-2983,78	2983,78	0,424731
				MAPE =	0,243633

Fonte: próprio autor.

Os modelos selecionados para aplicação com base na revisão bibliográfica foram os modelos de Wright, Stanford-B, DeJong e Curva-S já descritos na seção 2.5. Os parâmetros "B" para os modelos Stanford-B e Curva-S e "M" para os modelos DeJong e Curva-S foram definidos considerando as seguintes premissas:

- Parâmetro "B": como refere-se à experiência prévia dos operadores com fabricações anteriores e, neste caso, embora não tenha havido construção de protótipo para este modelo de aeronave, aproximadamente 20% dos operadores possuíam experiência prévia na montagem deste tipo de aeronave, pois foram enviados de outra unidade da empresa para auxiliar a montagem desta série junto aos novos operadores, o valor 1 será adotado para o parâmetro B;
- Parâmetro "M" (fator de incompressibilidade): serão utilizados os valores 0,05; 0,10; 0,15 e 0,20 conforme Moore (2015) e Moore et al. (2015) adotaram considerando que a montagem na indústria aeronáutica não é muito automatizada e, portanto, M deve aproximar-se mais de zero (0) do que de um (1) embora não exista na literatura uma classificação de M para cada tipo de indústria e portanto ele deve ser estimado com base na percepção do nível de automação do processo observado.

Os dados reais com a quantidade de horas por número de série foram submetidos à um teste de normalidade para verificar através da estatística de Anderson-Darling se os dados obtidos seguiam uma distribuição normal. Para tal, foi utilizado o suplemento do *software* MS Excel "Action Stat". A figura 6 mostra o resultado do teste.

Figura 6 - Resultado da estatística de Anderson-Darling

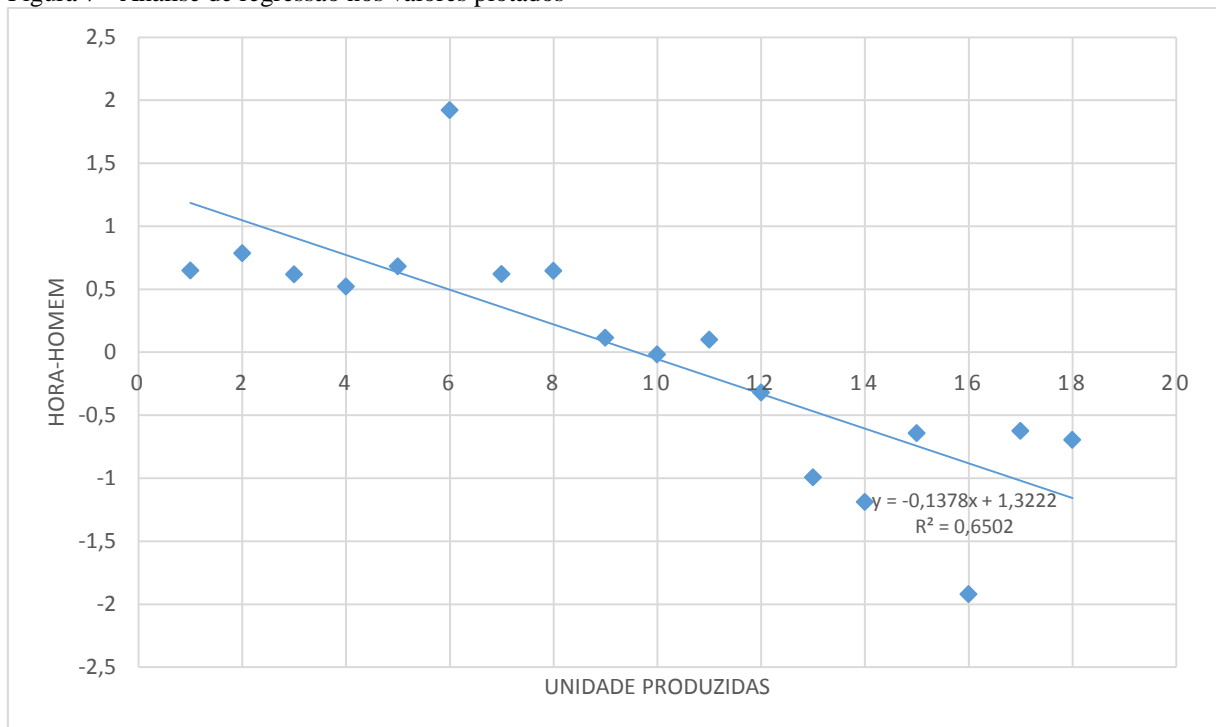
Testes de Normalidade		
Testes	Estatísticas	P-valores
Anderson - Darling	0,892850212	0,0177

Fonte: próprio autor

Como o p-valor associado ao teste de Anderson-Darling é menor que 0,05 rejeitou-se a hipótese de que a distribuição dos dados é aproximadamente normal. Dessa maneira, como

os dados reais não podem ser modelados por uma distribuição normal, será efetuada uma transformação nesses dados com o objetivo de encontrar normalidade através da transformação de Johnson, também com a utilização do suplemento “Action Stat”. Aplicando a Transformação de Johnson nos dados obteve-se novos valores e automaticamente o suplemento retornou também o novo p-valor, que para o teste Anderson-Darling foi 0,26 após a transformação, o que demonstra que a distribuição dos dados transformados é aproximadamente normal, pois é maior que 0,05. Os dados agora convertidos foram plotados em um gráfico para que fosse aplicada a regressão linear com a finalidade de se descobrir o fator "b" que é a inclinação da reta ( $b = -0,1378$ ). A partir dele, foi possível identificar a taxa de aprendizagem ( $R = 90,89\%$ ). A figura 7 demonstra a aplicação.

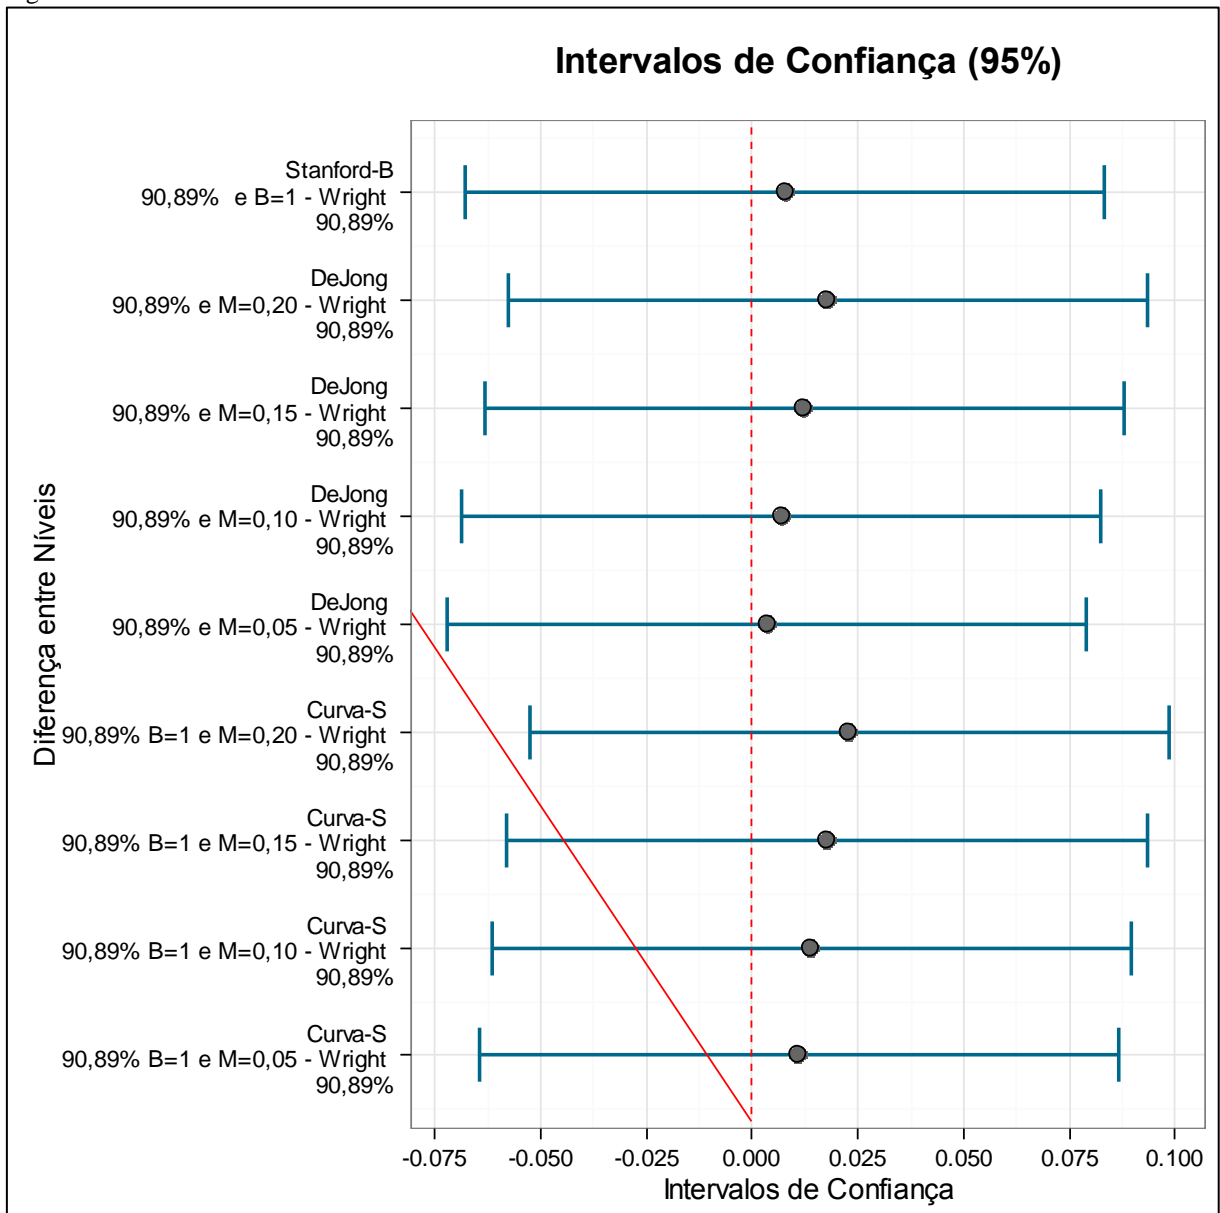
Figura 7 - Análise de regressão nos valores plotados



Fonte: próprio autor

O valor encontrado para R (95,27%) foi utilizado na previsão dos modelos de curva de aprendizagem selecionados (Wright, Standford-B, DeJong e Curva-S) e, a partir das previsões obtidas, o cálculo do erro absoluto de cada modelo foi efetuado obtendo-se os valores de MAPE que foram posteriormente comparados através do teste de Dunnett, como demonstra a figura 8.

Figura 8 – Resultado do teste de Dunnett



Fonte: próprio autor

No gráfico gerado pelo teste Dunnett é possível observar que o modelo de Stanford-B aproxima-se do modelo de Wright quando aplicado com o parâmetro  $B=1$ , ou seja, quando há pouca experiência prévia entre os trabalhadores enquanto o mesmo ocorre com o modelo DeJong quando aplicado com o parâmetro  $M=0,10$ , o que significa que há baixo grau de automação no processo produtivo. No entanto, o modelo DeJong com o fator de incompressibilidade  $M=0,05$  foi o que mais se aproximou do modelo de Wright. Com o incremento do fator de incompressibilidade “M”, a média do erro absoluto dos modelos DeJong e Curva-S que utilizam este parâmetro foi se distanciando da apresentada pelo modelo de Wright apresentando valores maiores do que este, o que demonstra que o erro destes

modelos foi maior que o erro apresentado pelo modelo de Wright. O modelo que mais se distanciou do modelo de Wright apresentando um valor maior de erro absoluto foi o modelo Curva-S.

#### 4.2 Fase 2 – Aplicação dos modelos com o auxílio dos estimadores Bayesianos

A segunda etapa consiste em executar a comparação dos modelos a partir da análise Bayesiana uma vez que esta permite determinar intervalos nas distribuições dos valores dos parâmetros utilizados pelos modelos selecionados dentro de limites pré-estabelecidos pelo usuário e os resultados não dependem de resultados assintóticos, ou seja, não dependem do tamanho amostral (neste caso 18 aeronaves) pois, utiliza-se métodos de Monte Carlo via cadeias de Markov (MCMC) obtendo-se resultados precisos. Os softwares OpenBugs e Minitab foram utilizados nesta etapa para efetuar a estimativa dos parâmetros e plotar o gráfico com os valores gerados. Esta segunda etapa foi executada em 3 passos, descritos a seguir:

- Passo 1: Utilização dos modelos de curvas de aprendizagem definidos na etapa 1 e definição dos limites dos parâmetros dos modelos para a aplicação;
- Passo 2: Plotagem dos modelos e limites dos parâmetros no *Software* OpenBugs e rodada com 1000 amostras para a geração dos valores previstos nos modelos a partir dos estimadores Bayesianos.
- Passo 3: Plotagem dos dados no Minitab para gerar os gráficos e efetuar o compare entre os modelos, verificando o que apresentou melhor ajuste aos dados reais.

Nesta etapa os parâmetros “B” e “M” utilizados pelos modelos foram estimados por meio da análise Bayesiana considerando limites pré-estabelecidos para eles de modo que fosse possível obter um melhor ajuste em relação aos dados reais coletados diferentemente do que ocorreu na etapa 1, onde os parâmetros foram pré-determinados com base nos valores encontrados na literatura. Desta forma, com base no modelos selecionados para aplicação na etapa 1 (Wright, Stanford-B, DeJong e Curva-S), os limites de variação do parâmetro "B" para os modelos Stanford-B e Curva-S e "M" para os modelos DeJong e Curva-S foram definidos considerando as seguintes premissas:

- Parâmetro "B": como refere-se à experiência prévia dos operadores com fabricações anteriores e, neste caso, embora não tenha havido construção de protótipo para este

modelo de aeronave, aproximadamente 20% dos operadores possuíam experiência prévia na montagem deste tipo de aeronave, pois foram enviados de outro site para auxiliar a montagem desta série junto aos novos operadores, nesta etapa o valor do parâmetro pode assumir qualquer valor entre 0 e 1, sendo este o intervalo no qual os estimadores bayesianos poderão trabalhar;

- Parâmetro "M" (fator de incompressibilidade): este parâmetro poderá variar entre 0,05 e 0,20 considerando que a montagem na indústria aeronáutica não é muito automatizada e, portanto, M deve aproximar-se mais de zero (0) do que de um (1) embora não exista na literatura uma classificação de M para cada tipo de indústria e portanto ele deve ser estimado com base na percepção do nível de automação do processo observado.

Os modelos selecionados bem como os limites de variação dos parâmetros “B” e “M” que os modelos deveriam considerar foram inseridos no *software* OpenBugs e 1000 amostras foram geradas pelo *software* para a estimativa dos valores dos parâmetros em cada modelo. Os valores gerados são apresentados na tabela 2.

Tabela 2 – Estimativa dos parâmetros pelo método Bayesiano.

Modelo	Parâmetro	média	desvio padrão	limite inferior	limite superior
Modelo de Wright	$\sigma^2$	-0.111	0.02165	-0.1544	-0.06706
		1374.0	233.9	1003.0	1924.0
Modelo de Stanford-B	B	0.4252	0.2794	0.02032	0.9515
	b	0.1086	0.02119	0.0688	0.1539
	$\sigma^2$	1411.0	250.2	1021.0	1976.0
Modelo DeJong	M	0.104	0.05793	0.004062	0.1954
	b	0.1273	0.02548	0.07991	0.1796
	$\sigma^2$	1379.0	239.8	1011.0	1911.0
	B	0.4876	0.2917	0.02818	0.9686
Modelo Curva-S	M	0.09919	0.05829	0.004068	0.1947
	b	0.000228	0.9993	-1.874	2.103
	$\sigma^2$	2350.0	386.8	1750.0	3204.0

Fonte: próprio autor.

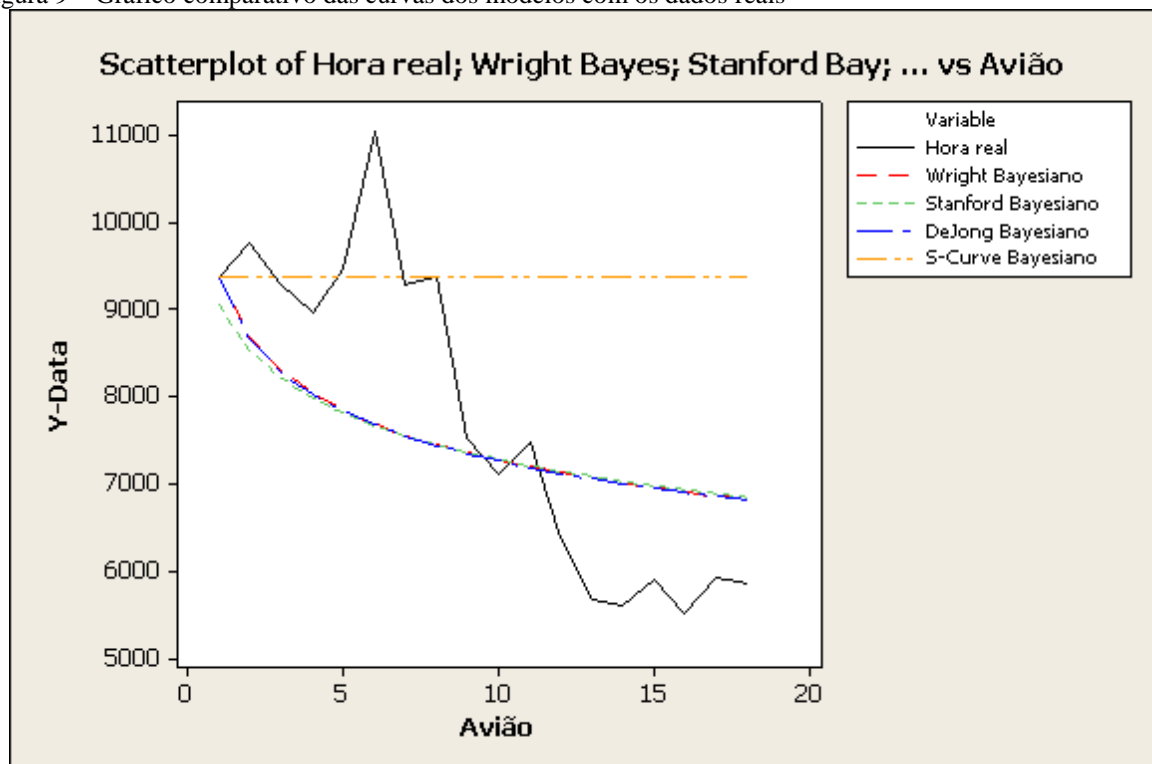
O valor do parâmetro “B” que refere-se à experiência prévia dos trabalhadores tanto no modelo de Stanford-B quando no modelo de Curva-S apresentou uma média de 0,425 e 0,487, respectivamente, o que refletiu a baixa experiência existente entre os operadores, o que

já era esperado uma vez que não houve a construção de protótipo ou experiência prévia com produtos similares por grande parte dos trabalhadores nessa planta da empresa.

O valor do parâmetro “M” que refere-se ao grau de automação do processo produtivo apresentou uma média de 0,104 e 0,099 nos modelos DeJong e Curva-S, respectivamente, valores que indicam um baixo grau de automação no processo de produção, o que também condiz com a realidade do processo estudado caracterizado por operadores altamente qualificados que utilizam instrumentos e ferramentas de montagem e medição, sem a utilização de máquinas ou robôs, similarmente à produção artesanal.

Os valores gerados pelos modelos selecionados para os números de série da aeronave em questão com os parâmetros definidos pelos estimadores bayesianos foram plotados em um gráfico através do Software Minitab para facilitar a visualização das curvas de aprendizagem geradas por cada modelo, conforme mostra a figura 9. Nela, é possível observar que os valores gerados pelos modelos de curva de aprendizagem de Wright, Stanford-B e DeJong a partir dos parâmetros estimados estatisticamente são muito próximos entre si enquanto o modelo Curva-S apresentou uma reta indicando que não houve um bom ajuste deste modelo aos dados reais e tampouco aos dados gerados pelos demais modelos. Os dados com os valores de hora-homem reais extraídos dos documentos da organização também foram plotados para referência.

Figura 9 – Gráfico comparativo das curvas dos modelos com os dados reais



Fonte: próprio autor

O critério Bayesiano DIC (ver Apêndice A), apresentou os seguintes valores: Wright (315.2), Stanford (315.4), DeJong (315,0) e Curva-S (333.2). Os três primeiros modelos têm valor DIC (*Deviance Information Criterion*) ou critério para discriminação de modelos, em português, muito próximos e o modelo Curva-S tem valor DIC muito maior, evidenciando a discrepância dos valores gerados por este último modelo.

## 5 CONCLUSÕES

Com base nos resultados obtidos durante a primeira fase da aplicação, é possível observar que nenhum modelo apresentou uma MAPE menor que a apresentada pelo modelo de Wright nesta aplicação, no entanto, os modelos Stanford-B com o parâmetro de experiência anterior  $"B"=1$ , o modelo DeJong com o fator de incompressibilidade  $"M"=0,10$  se aproximaram do valor da MAPE obtida pelo modelo de Wright, embora o modelo DeJong com o fator de incompressibilidade  $"M"=0,05$  tenha se aproximado mais do modelo de Wright, o que demonstra que este modelo pode ser adotado pela organização nos casos em que o nível de automação representado pelo parâmetro M for igual à 0,05, o que significa um nível de automação baixo, como já é esperado em produções de aeronaves. Nos casos em que os níveis de automação forem maiores fazendo com que o fator de incompressibilidade "M" assumam valores superiores à 0,05, os modelos que utilizam este parâmetro (DeJong e Curva-S) não devem ser adotados pela organização. O modelo Curva-S foi o modelo que apresentou o maior percentual de erro absoluto, distanciando-se mais do modelo de Wright, e portanto demonstrou não ser adequado para este tipo de aplicação.

Como nenhum outro modelo apresentou um percentual de erro absoluto inferior ao modelo de Wright, este pode ser considerado o modelo mais preciso neste caso e, portanto, recomenda-se sua utilização pois, além de possuir a menor média de percentual do erro absoluto, é também o mais simples dos modelos considerados.

Com base nos resultados observados na segunda fase da aplicação, é possível concluir que os melhores modelos para esta aplicação são os modelos de Wright, Stanford-B e DeJong pois, segundo o critério Bayesiano DIC, os modelos apresentaram valores próximos e considerados bons enquanto o modelo Curva-S apresentou uma alta discrepância, indicando que o modelo não teve um bom ajuste aos dados reais observados no chão de fábrica e portanto não deveria ser adotado pela organização, como já foi possível concluir com base nos resultados apresentados durante a primeira fase da aplicação.

Além de apresentar os modelos mais adequados para a aplicação, principal objetivo do trabalho, a pesquisa permitiu concluir que a estimativa dos parâmetros utilizados nos modelos de curvas de aprendizagem por meio dos estimadores Bayesianos com a utilização da simulação Monte Carlo via Cadeias de Markov se mostra mais precisa uma vez que as curvas de aprendizagem são plotadas a partir de parâmetros ajustados por computador para se obter o melhor ajuste em relação aos dados reais. Embora trate-se de uma análise mais complexa que requer simulação computacional se comparada à determinação prévia dos parâmetros com



base na literatura, se for considerada a relevância da acurácia dos dados previstos por meio das curvas de aprendizagem para melhor suportar a tomada de decisão nas organizações, este método se mostra uma escolha mais adequada.

Considerando-se a importância de se trabalhar com parâmetros precisos para se obter maior acurácia nos dados gerados pelo modelo de curva de aprendizagem selecionado, ficou evidente que compreender os fatores que influenciam as variações das taxas de aprendizagem é fundamental uma vez que a partir desta compreensão é possível determinar ações que ampliem a aprendizagem na organização, fazendo com que o decréscimo das horas de trabalho e custos associados aos produtos fabricados seja maior na medida em que a quantidade acumulada do produto aumenta, expandindo a produtividade da empresa. Desta forma, as organizações podem direcionar seus esforços priorizando os fatores que mais contribuem com o aumento da aprendizagem na empresa, sejam eles treinamentos, melhorias em ferramentais ou procedimentos, alterações no fluxo de material, mudanças de layout, alterações de tecnologia, mudanças no produto, etc.

Outro ponto importante observado durante o desenvolvimento dessa pesquisa é a lacuna existente na literatura de trabalhos que demonstrem a utilização das curvas de aprendizagem pelas organizações no auxílio da tomada de decisão no planejamento operacional, tático e estratégico, pois grande parte dos trabalhos tem como objetivo encontrar o modelo de curva de aprendizagem mais adequado para utilização na geração dos dados de hora-homem ou custo do produto ao longo do tempo, não demonstrando o que é feito após a previsão destes valores. Sugere-se então que trabalhos futuros explorem essas aplicações.

## REFERÊNCIAS

- ABERNATHY W.J.; WAYNE, K. Limits of the Learning Curve. **Harvard Business Review**, pp. 109-19, Set-Out. 1974.
- ADLER, P.S.; CLARK, K.B. Behind the learning curve: A sketch of the learning process. **Management Science** 37 (3), 267-281, 1991.
- ALCHIAN, A. Reliability of Progress Curves in Airframe Production. **RAND Corporation** (Report 260-1), Santa Monica, Califórnia, Abr. 1950.
- ANZANELLO, M.J.; FOGLIATTO, F.S. Alocação de modelos de produtos a equipes de trabalhadores baseada em modelos de curvas de aprendizagem. **Revista Produção**, v. 15, n. 2, p. 221-234, Maio/Ago. 2005.
- ANZANELLO, M.J.; FOGLIATTO, F.S. Curvas de aprendizado: estado da arte e perspectivas de pesquisa. **Gestão da Produção**, São Carlos, v. 14, n. 1, p. 109-123, jan.-abr. 2007.
- ANZANELLO, M.J.; FOGLIATTO, F.S. Modelagem de curvas de aprendizado para alocação de produtos com lotes de tamanho variável a equipes de trabalhadores. **XXIV Encontro Nac. de Eng. de Produção** - Florianópolis, SC, Brasil, 2004.
- ARGOTE, L. Organizational learning: Creating, retaining and transferring knowledge. **Springer Science & Business Media**, 2012.
- ARGOTE, L.; EPPLE, D. Learning curves in manufacturing. **Science**, 247, 920–924, 1990.
- ARGOTE, L.; McEVILY, B.; REAGANS, R. Managing Knowledge in Organizations: An Integrative Framework and Review of Emerging Themes. **Management Science**, Vol. 49, No. 4, pp. 571-582, 2003.
- ATTIA, E.; MEGAHED, A.; DUQUENNE, P. Towards a learning curve for electric motors production under organizational learning via shop floor data. **International Federation of Automatic Control**, PapersOnLine 49(12):1086-1091, 2016.
- AZIZI, N.; ZOLFAGHARI, S.; LIANG, M. Modeling job rotation in manufacturing systems: The study of employee's boredom and skill variations. **International Journal of Production Economics**, v. 123, n. 1, p. 69-85, 2010.
- BADIRU, A. B. Computational Survey of Univariate and Multivariate Learning Curve Models. **IEEE Transactions on Engineering Management**, New Jersey, v. 39, n. 2, p. 176-188, 1992.
- BADIRU, A. B. Half-Life Learning Curves in the Defense Acquisition Lifecycle. **Defense Acquisition Research Journal**, Vol. 19, No. 3, pp. 283-308, 2012.
- BADIRU, A.B. Multifactor Learning and Forgetting Models for Productivity and Performance Analysis. **International Journal of Human Factors in Manufacturing**, Vol. 4, No.1, pp. 37-54, 1994.

BADRI, H.M.; DEROS, B.M.; SYAHRI, M.; SALEH, C.; FITRIA, A. Implementation Learning and Forgetting Curve to Scheduling in Garment Industry. **IOP Conf. Series: Materials Science and Engineering**, 114, 2016.

BAILEY, C. D.; McINTYRE, E. V. The Relation between Fit and Prediction for Alternative Forms of Learning Curves and Relearning Curves. **IIE Transactions**, London, v. 29, n. 6, p. 487-495, 1997.

BAILEY, C.D. Forgetting and the learning curve: A laboratory study. **Manage. Sci.**, 35, pp. 346–352, 1989.

BENEITO, P.; ENGRACIA, M.R-B.; SANCHIS, A. Learning through experience in Research & Development: An empirical analysis with Spanish firms. **Technological Forecasting & Social Change**, 88, 290–305, 2014.

BENKARD, C. L. Learning And Forgetting: The Dynamics Of Aircraft Production. **American Economic Review**, Vol. 90, p. 1034-1054, 2000.

CABRAL, L.M.; RIORDAN, M.H. The Learning Curve, Market Dominance and Predatory Pricing. **Econometrica**, 62, pp. 1115-1140, 1994.

CADAVAL JR, T.R.S.; DUARTE, E.H.; PAES, R.L. Curvas de aprendizado aplicadas a análise da produtividade de soldadores. **Vetor**, Rio Grande, v. 23, n. 2, p.29-38, 2013.

CARLSON, J. G.; ROWE, R. G. How much does forgetting cost?. **Indust. Eng.** 8 (9), pp. 40-47, 1976.

DAR-EL, E. Human Learning: from Learning Curves to Learning Organizations, New York: **Springer**, 2000.

DUTTON, J.M.; THOMAS, A. Treating Progress Functions as a Managerial Opportunity. **The Academy of Management Review**, Vol. 9, No. 2., pp. 235-247, 1984.

FIORETTI, G. The organizational learning curve. **European Journal of Operational Research** 177, pp. 1375–1384, 2007.

FREY, S.; DIAWATI, L.; CAKRAVASTIA, A. Learning curves in automobile assembly line. **Proceedings of the 16th Annual International Conference on Industrial Engineering Theory, Applications and Practice Stuttgart**, Germany, September 20-23, 2011.

GLOBERSON, S.; LEVIN, N. Incorporating Forgetting into Learning curves. **International Journal of Operation & Production Management**, Vol. 7, No. 4, 1987.

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

GRAHAME, S. The learning curve: the key to future management? **Project Report. Chartered Institute of Management Accountants**, London, 2010.

GROSSE, E.H.; GLOCK, C.H.; MÜLLER, S. Production economics and the learning curve: A meta-analysis. **Int. J. Production Economics**, 170, pp. 401–412, 2015.

HARTLEY, K. The Learning Curve and Its Application to the Aircraft Industry. **The Journal of Industrial Economics**, Vol. 13, No. 2, pp. 122-128, Mar. 1965.

HENG, T.M. Learning curves and productivity in Singapore manufacturing industries. **Second Annual Conference of the Academic Network for Development in Asia (ANDA)**, Phnom Penh, Cambodia, 8-10 Jan.2010.

HIRSCHMANN, W.B. Profit from the Learning Curve. **Harvard Business Review**, p. 125. 6, Jan-Fev. 1964.

HOCKENBERRY, J.M. The impacts of task repetition and temporal breaks in production on human capital and productivity. **Journal of Human Capital**, 2(3):303-335, 2008.

JABER, M. Y.; BONNEY, M. A Comparative Study of Learning Curves with Forgetting. **Applied Mathematical Modeling**, New York, v. 21, n. 8, p. 523-531, 1997.

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**, New York, v. 59, n. 1-3, p. 93-102, 1999.

JABER, M. Y.; GUIFFRIDA, A.L. Learning curves for imperfect production processes with reworks and process restoration interruptions. **European Journal of Operational Research** 189, pp. 93–104, 2008.

JABER, M.; GUIFFRIDA, A. Learning Curves for Process Generating Defects Requiring Reworks, **European Journal of Production Research, Netherlands**, v. 159, n. 1, p. 663-672, 2004.

JABER, M.Y.; BONNEY, M. Production breaks and the learning curve: The forgetting phenomenon. **Applied Mathematical Modelling**. Vol 20, Issue 2, pp. 162-169, 1996.

JABER, M.Y.; KHER, H.V. The dual-phase learning-forgetting model. **International Journal of Production Economics** 76, pp. 229-242, 2002.

JABER, M.Y.; SIKSTROM, S. A numerical comparison of three potential learning and forgetting models. **Int. J. Production Economics** 92, pp.281–294, 2004.

KAPP, K.M. Transforming your manufacturing organization into a learning organization. **Hospital Material Management Quarterly** 20, 46-54, 1999.

KEACHIE, E. C.; FONTANA, R. J. Production lot sizing under a learning effect. **Management Science**, v. 13, n. 2, p. 102-108, 1966.

KREDLER, M. Vintage human capital and learning curves. **Journal of Economic Dynamics and Control**, vol. 40, issue C, pp. 154-178, 2014.

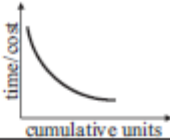
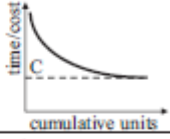
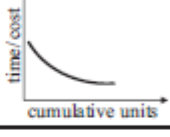
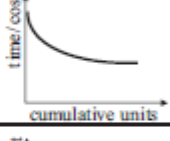
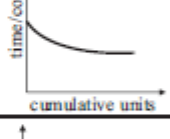
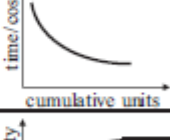
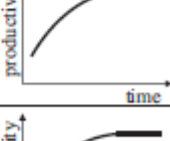
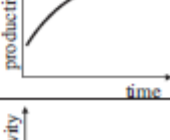
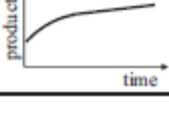
LINTON, J. D.; WALSH, S. T. Integrating innovation and learning curve theory: an enabler for moving nanotechnologies and other emerging process technologies into production. **R&D Management**, 34, pp. 517–526, 2004.

MALYUSZ, L.; PEM, A. Predicting future performance by learning curves. **Procedia - Social and Behavioral Sciences** 119, pp. 368 – 376, 2014.

- MALYUSZ, L.; PEM, A. Prediction of the learning curve in roof insulation. **Automation in Construction** 36, pp. 191–195, 2013.
- MARTINEZ, I.A.G.; REVILLA, J.A.D. Investigating the effect on the learning curve of performing similar work during the break between work stints. **Procedia Manufacturing** 3, pp.3456 – 3462, 2015.
- MIGUEL, P.A.C. Estudo de caso na engenharia de produção: estruturação e recomendações para sua condução. **Revista Produção**, v. 17, n. 1, p. 216-229, Jan./Abr. 2007.
- MOORE, J.R. **A comparative study of learning curve models in defense airframe cost estimating**. 2015. f.90. Thesis of Master of Science in Cost Analysis. Department of the air force air university. Wright-Patterson Air Force Base, Ohio. 2015.
- MOORE, J.R.; ELSHAW, J.J.; BADIRU, A.B.; RITSCHER, J.D. **Defense Acquisition Research Journal: A Publication of the Defense Acquisition University**, Vol. 22 Issue 4, p416-449, 34p, Oct. 2015.
- NEMBHARD, D. A.; OSOTHSILP, N. Task Complexity Effects on Between-Individual Learning/Forgetting Variability. **International Journal of Industrial Ergonomics**, London, v. 29, n. 5, p. 297-306, 2002.
- NEMBHARD, D. A.; UZUMERI, M. V. Experimental Learning and Forgetting for Manual and Cognitive Tasks. **International Journal of Industrial Ergonomics**, London, v. 25, n. 3, p. 315-326, 2000.
- NEMET, G.F. Beyond the learning curve: factors influencing cost reductions in photovoltaics. **Energy Policy**, 34, pp.3218–3232, 2006.
- PEDROSO, M. C.; CORREA, H. L. Sistemas de programação da produção com capacidade finita: uma decisão estratégica? **Revista de Administração de Empresas**, v. 36, n. 4, p. 60-73, 1996.
- PENDHARKAR, P. C.; SUBRAMANIAN, G. H. An empirical study of ICASE learning curves and probability bounds for software development effort. **European Journal of Operational Research**, v. 183, n. 3, p. 1086-1096, 2007.
- PISANO, G. P. Towards a Prescriptive Theory of Dynamic Capabilities: Connecting Strategic Choice, Learning, and Competition. **Harvard Business School Working Paper**, No. 16-146, Jun. 2016.
- PLAZA, M.; NGWENYAMA, O.K.; ROHLF, K. A comparative analysis of learning curves: Implications for new technology implementation management. **European Journal of Operational Research** 200(2):518-528, Mai. 2010.
- REMOR, L.C.; MIRANDA, A.C.D.; SANTOS, N.; STEIL, A.V.; REMOR, C.A.M. Esquecimento organizacional e suas consequências no processo de aprendizagem organizacional. **Revista de Administração Pública**. Rio de Janeiro 44(3):667-78, Mai/Jun. 2010.

- SCHOOTS, K.; KRAMER, G. J.; van der ZWAAN, B.C.C. Technology learning for fuel cells: An assessment of past and potential cost reductions. **Energy Policy**, v. 38, n. 6, p. 2887-2897, 2010.
- SHAFER, S. M.; NEMBHARD, D. A.; UZUMERI, M. V. The Effects of Worker Learning, Forgetting, and Heterogeneity on Assembly Line Productivity. **Management Science**, v. 47, n. 12, p. 1639-1653, 2001.
- SILAYO, S.A.; MIGUNGA, G.A.; SHEMWETTA, D.T.K. Determination of Learning Curves and Forgetting Factors of Two-man Crosscut Saw Operators during Tree Cutting Operations in a 'Learn by Doing' Experiment. **American Journal of Environmental Engineering**, 4(5): 106-116, 2014.
- SMUNT, T. Rough Cut Capacity Planning in a Learning Environment. **IEEE transactions on engineering management**, Vol. 43, No. 3, 1996.
- SMUNT, T.L.; WATTS, C.A. Improving operations planning with learning curves: overcoming the pitfalls of 'messy' shop floor data. **Journal of Operations Management** 21, pp. 93–107, 2003.
- SPENCE, A. M. The Learning Curve and Competition. **The Bell Journal of Economics**, Vol. 12, No. 1, pp. 49-70, 1981.
- THOMASSEN, A. Learning and forgetting curves: a practical study. **33rd Annual Operational Research Society of New Zealand Conference**, pp. 89-98, 1998.
- TOWILL, D. R. Management Systems Applications of Learning Curves and Progress Functions. **Engineering Costs and Production Economics**, Netherlands, 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** 16, p. 515–528, 1998.
- VENTURA, M. M. O estudo de caso como modalidade de pesquisa. **Revista SOCERJ**, 20(5):383-386. Set/Out. 2007.
- WIERSMA, E. Conditions That Shape the Learning Curve: Factors That Increase the Ability and Opportunity to Learn. **Management Science** 53(12):1903-1915, 2007.
- WRIGHT, T. P. Factors Affecting the Cost of Airplanes. **Journal of the Aeronautical Sciences**, London, v. 3, p. 122-128, 1936.
- YIN, R. K. Estudo de Caso: planejamento e métodos. Tradução Daniel Grassi. 2º ed. Porto Alegre: **Bookman**, 2001.
- YELLE, L. E. The Learning Curve: Historical Review and Comprehensive Survey. **Decision Science**, London, v. 10, n. 2, p. 302-328, 1979.

## ANEXO A - PRINCIPAIS CURVAS DE APRENDIZAGEM

Nr	Learning-Curve	Model	Usually measures learning as	Typical learning curve
1	WLC	$y_x = y_1 \cdot x^{-b}$	reduction in time/cost	
2	PM	$y_x = C + y_1 \cdot x^{-b}$	reduction in time/cost	
3	SBM	$y_x = y_1 \cdot (x + B)^{-b}$	reduction in time/cost	
4	DJM	$y_x = y_1 \cdot (M + (1 - M) \cdot x^{-b})$	reduction in time/cost	
5	SCM	$y_x = y_1 \cdot (M + (1 - M) \cdot (x + B)^{-b})$	reduction in time/cost	
6	JGLCM	$y_x = p \cdot y_1 \cdot x^{-bc} + (1 - p) \cdot y_1 \cdot x^{-bm}$	reduction in time/cost	
7	2PE	$y = k \cdot \left(1 - e^{-\frac{t}{R}}\right)$	increase in output/productivity	
8	3PE	$y = k \cdot \left(1 - e^{-\frac{(t+p)}{R}}\right)$	increase in output/productivity	
9	GLC	$Z(T) = \sum_{l=1}^n Y_l(T) + \sum_{l=1}^n \sum_{j=1}^n X_{l,j}(T)$	increase in output/productivity	

**Fonte:** Production economics and the learning curve: A meta-analysis

Eric H.Grosse, ChristophH. Glock, Sebastian Müller

Institute of Production and Supply Chain Management, Technische Universität Darmstadt, Hochschulstr. 1, 64289 Darmstadt, Germany

## APÊNDICE A - BREVE REVISÃO DA METODOLOGIA BAYESIANA

Os métodos bayesianos têm sido considerados alternativas muito eficazes e poderosas na análise de dados. Esse método possui uma filosofia muito diferente do método frequentista. No método clássico, os parâmetros do modelo são considerados constantes desconhecidas, e no método bayesiano todos os parâmetros são considerados quantidades aleatórias. Uma característica muito importante é o fato desta análise permitir a incorporação da informação de um especialista junto à informação dos dados.

A inferência bayesiana tem como fundamentação a Fórmula de Bayes, a qual combina os dados com a informação *a priori* e, então, se obtém *a posteriori* (*priori* já complementada pela informação dos dados), onde é realizado todo o processo inferencial (Box e Tiao, 1973; Paulino et al., 2003).

### Fórmulas de Bayes

Considere uma partição do espaço amostral  $\Omega$ , onde os eventos  $A_1, A_2, \dots, A_K$  formam uma sequência de eventos mutuamente exclusivos e exaustivos, isto é,  $\cup_{j=1}^k A_j = \Omega$  e  $A_i \cap A_j = \emptyset$  (conjunto vazio) para  $i \neq j$  tal que  $P(\cup_{j=1}^k A_j) = \sum_{j=1}^k P(A_j) = 1$ .

Sendo assim para qualquer outro evento B ( $B \subset \Omega$ ), temos,

$$P(A_i | B) = \frac{P(A_i | B) P(A_i)}{\sum_{j=1}^k P(A_j | B) P(A_j)} \quad (1)$$

Para todo  $i$  variando de 1 a  $k$ .

Assumindo agora um vetor de dados  $y = (y_1, \dots, y_n)'$  e  $\theta$  (quantidades desconhecidas) os parâmetros de uma distribuição de probabilidade associada com a variável aleatória  $Y_i$  com valores observados em  $y_i, i = 1, \dots, n$ .

Considere  $y = (y_1, \dots, y_n)$  uma amostra aleatória onde os dados são independentes e identicamente distribuídos. Suponha que  $y$  é um vetor de observações de uma distribuição conjunta dada por  $f(y | \theta)$  e seja  $\pi(\theta)$  uma distribuição a priori para  $\theta$ . Então, assumindo os valores discretos  $\theta_1, \dots, \theta_k$ , temos de (1) a distribuição a posteriori para  $\theta_i$  dado  $y$  é dado por

$$\pi(\theta_i | y) = \frac{f(y | \theta_i) \pi(\theta_i)}{\sum_{j=1}^k f(y | \theta_j) \pi(\theta_j)} \quad (2)$$

Onde o parâmetro  $\theta$  também é considerado como uma quantidade aleatória, no enfoque bayesiano.

Para  $\theta$  assumindo valores contínuos num dado intervalo, podemos escrever (2) por

$$\pi(\theta | y) = \frac{f(y | \theta) \pi(\theta)}{\int f(y | \theta) \pi(\theta) d\theta} \quad (3)$$

Em que a integral no denominador de (3) é definida no intervalo de variação de  $\theta$ .

### Distribuição *a Priori*

Na análise bayesiana, a distribuição *a priori* é utilizada a fim de representar o que já é conhecido sobre parâmetros desconhecidos, antes de se avaliar os dados. Deve-se ter muita cautela ao definir uma distribuição *a priori*, afinal se esta informação não for bem definida pode-se chegar a interpretações errôneas. Uma distribuição *a priori* para um parâmetro pode



se dar de várias formas, sendo possível ocorrerem a partir de procedimentos subjetivos ou objetivos.

A distribuição *a priori* conjugada é uma *priori* informativa, onde a distribuição *a priori* e *a posteriori* pertencem à mesma classe de distribuições. A passagem de *priori* para a *posteriori* envolve apenas uma simples mudança nos parâmetros, sem a necessidade de cálculos adicionais (Paulino et al., 2003).

A distribuição *a priori* também pode ser a incorporação do conhecimento de um pesquisador, ou seja, o pesquisador se baseia na sua prática e no seu “*feeling*” para definir a *priori*. Em muitas situações práticas esse conhecimento do especialista não existe ou, se existe, não é fidedigno. Nesse caso, caracteriza-se uma “ignorância *a priori*” (Paulino et al., 2003).

Nestas situações são utilizadas *as prioris* não informativas, ou seja, *prioris* de referência “neutras” (Box e Tiao, 1973). A utilização deste tipo de distribuição *a priori* permite a comparação com os resultados obtidos pela inferência clássica, haja visto que através de uma *priori* não informativa, o modelo é baseado apenas na informação dos dados amostrais. Existem vários métodos para se definir a *priori* não informativa, como por exemplo: Método de Bayes- Laplace, Método de Jeffreys, entre outros Box e Tiao, 1973; Paulino et al., 2003).

### **Métodos de Simulação para amostras da distribuição *a posteriori***

Para a obtenção de sumários *a posteriori* de interesse, geralmente é necessário resolver integrais bayesianas que não apresentam solução analítica. Na prática, observa-se que os modelos utilizados nem sempre são simples para se obter os resumos *a posteriori*. Mesmo que se tenha uma *priori* e uma verossimilhança simples, a junção delas pode produzir uma distribuição *a posteriori* muito complicada (Paulino et al., 2003).

Os métodos com base em amostragem, como, por exemplo, o método de Monte Carlo com cadeias de Markov (MCMC), passaram a ser utilizados com o avanço das técnicas computacionais. Esse método consiste na simulação de uma variável aleatória através de uma cadeia de Markov, no qual a sua distribuição assintoticamente se aproxima da distribuição *a posteriori* (Bernardo e Smith, 1994).

A cadeia de Markov é um processo estocástico no qual o próximo estado da cadeia depende somente do estado atual e dos dados. No entanto, existe uma relação com o estado inicial, que é descartado após um período de aquecimento, o chamado “*Burn-in*”.

As formas mais usuais dos métodos MCMC são os amostradores de Gibbs e o algoritmo de Metropolis-Hastings. Estas duas formas simulam amostras da distribuição *a posteriori* conjunta a partir das distribuições condicionais (Gelfand e Smith 1990; Chib e Greenberg, 1995).

O amostrador de Gibbs nos permite gerar amostras da distribuição *a posteriori* conjunta desde que as distribuições condicionais completas possuam formas fechadas ou conhecidas. Por outro lado, o algoritmo de Metropolis-Hastings permite gerar amostras da distribuição *a posteriori* conjunta com distribuições condicionais completas possuindo ou não uma forma conhecida ou fechada.

### Amostrador de Gibbs

Suponha  $\pi(\theta | y)$  uma distribuição *a posteriori* conjunta, sendo  $\theta = (\theta_1, \dots, \theta_k)$ , no qual desejamos obter inferências. Para isso, simulam-se quantidades aleatórias de distribuições condicionais completas  $\pi(\theta_i | y, \theta_{(i)})$ .

Considere os valores iniciais (arbitrários) para  $\theta: \theta_1^{(0)}, \theta_2^{(0)}, \dots, \theta_k$ . Desta forma, segue o seguinte algoritmo:

- Gerar  $\theta_1^{(1)}$  de  $\pi(\theta_1 | y, \theta_2^{(0)}, \dots, \theta_k^{(0)})$ ;
- Gerar  $\theta_2^{(1)}$  de  $\pi(\theta_2 | y, \theta_1^{(1)}, \theta_3^{(0)}, \dots, \theta_k^{(0)})$ ;
- (...)
- Gerar  $\theta_k^{(1)}$  de  $\pi(\theta_k | y, \theta_1^{(1)}, \theta_2^{(1)}, \dots, \theta_{k-1}^{(1)})$ .

Substitua os valores iniciais por  $\theta^{(1)} = (\theta_1^{(1)}, \theta_2^{(1)}, \dots, \theta_k^{(1)})$ , para uma nova realização. Os valores  $\theta_1^{(z)}, \theta_2^{(z)}, \dots, \theta_k^{(z)}$ , para  $z$  suficientemente grande, convergem para um valor da quantidade aleatória com distribuição  $\pi(\theta | y)$  (Bernardo e Smith, 1994, p. 353; Casela e George, 1992).

### Algoritmo de Metropolis Hastings

Suponha uma amostra de densidade não regular  $\pi(\theta_i | \theta_{(i)})$ , em que  $\theta_{(i)} = \theta_{i-1}, \theta_{i+1}, \dots, \theta_k$ . Seja  $q(\theta, \beta)$  o núcleo de transição da distribuição  $p(\theta)$  que representa  $\pi(\theta_i | \theta_{(i)})$  e que transforma  $\theta$  em  $\beta$ .

Desta forma o algoritmo dado por:

- Inicie com  $\theta^{(0)}$  e indicador de estado  $j = 0$ ;
- Gerar um ponto  $\beta$  do núcleo de transição  $q(\theta^{(j)}, \beta)$ ;
- Atualizar  $\theta^{(j)}$  por  $\theta^{(j+1)} = \beta$ , com probabilidade,  $p = \min \left\{ \frac{p(\beta)q[\theta^{(j)}, \beta]}{p[\theta^{(j)}]q[\beta, \theta^{(j)}]} \right\}$ , ficar com  $\theta^{(j)}$  com probabilidade  $1 - p$ ;
- Repetir os dois últimos passos até conseguir uma distribuição estacionária.

Importante observar: se um valor candidato é rejeitado, então o valor atual é considerado na próxima etapa; no terceiro passo o valor de  $p$  não depende da constante normalizadora; o algoritmo de Metropolis Hasting é especificado pela densidade candidata para geração  $q(x, y) ((\theta | y)$  (Bernardo e Smith, 1994; Chib e Greenberg, 1995).

Na prática podemos usar alguns programas computacionais na simulação de amostras da distribuição *a posteriori* de interesse. Um software muito popular e livre é o software *OpenBugs* (versão nova do software *WinBugs*). Com o uso desse software o trabalho de simulação fica muito simplificado.

### 3. Critério para Discriminação de Modelos - Deviance Information Criterion (DIC)

Para a discriminação do melhor modelo, usamos o critério DIC. O critério DIC (Spiegelhalter et al., 2002) é baseado na média a posteriori da deviance. Define-se a deviance por,

$$D(\boldsymbol{\theta}) = -2 \ln L(\boldsymbol{\theta}) + C \quad (10)$$

em que  $\boldsymbol{\theta}$  é um vetor de parâmetros desconhecidos do modelo;  $L(\boldsymbol{\theta})$  é a verossimilhança e  $C$  é uma constante (nem sempre conhecida) na comparação de dois modelos.

O critério DIC é dado então por

$$D(\boldsymbol{\theta}) = D(\hat{\boldsymbol{\theta}}) + 2p_D, \quad (11)$$

em que  $D(\hat{\boldsymbol{\theta}})$  é o desvio calculado na média a posteriori  $\hat{\boldsymbol{\theta}} = E(\boldsymbol{\theta}|y)$  e  $p_D$  é o número de parâmetros do modelo, dado por  $p_D = \bar{D} - D(\hat{\boldsymbol{\theta}})$  em que  $\bar{D} = E[D(\boldsymbol{\theta}|y)]$  é a média a posteriori do desvio que mede a qualidade do ajuste dos dados para cada modelo. Menores valores de DIC indicam melhores modelos.

### Referências

BATES, D.M. ; WATTS, D.G. *Nonlinear Regression Analysis and Its Applications*, Wiley, New York,1988, 392 p.

BATES, D.M. ; WATTS, D.G. Relative curvature measures of nonlinearity (with discussion), *Journal of the Royal Statistical Society, Series B* , v. 42, n.1, p.1-25,1980.

BERNARDO,J.M.; SMITH,A.F.M. *Bayesian Theory*, Wiley, 1994.

BOX,G.E.P.; TIAO,G.C. *Bayesian inference in statistical analysis*,Reading: Addison-Wesley, 1973.

CASELLA, G.; GEORGE, E. I. Explaining the Gibbs Sampler. *The American Statistician*, v.46, n.3,p.167-174,1992.

CHIB, S.; GREENBERG, E. Understanding the Metropolis- Hastings algorithm, *The American Statistician*, v.49, n.4, p.327-333,1995.

GELFAND, A. E.; SMITH, A.F.M. Sampling based approaches to calculating marginal densities, *Journal of the American Statistical Association*, v.85, n.410,p. 398-409,1990.

PAULINO, C.D.; TURKMAN, M.A.A.; MURTEIRA,B.*Estatística Bayesiana*. Fundação Calouste Gulbenkian, Lisboa, 2003.

RATKOWSKY, D.A. *Nonlinear Regression Modelling: A Unified Practical Approach*, Marcel Dekker, New York,1983, 288 p.

SEBER, G.A.F. ; WILD, C.J. *Nonlinear Regression*, Wiley, New York,1989,792 p.  
SPIEGELHALTER, D.J.; THOMAS, A.; BEST, N.G.; LUNN, D. *WinBugs User's Manual*, MRC Biostatistics Unit, Cambridge, 2003.

SPIEGELHALTER, D.J.; BEST, N. G., CARLIN, B. P., BAN DER LINDE, A.  
Bayesian measures of model complexity and fit, *Journal of the Royal Statistical Society*,  
Series B, v.64, n.4, p.583-639,2002.