Redes Bayesianas para dar suporte ao planejamento da inspeção na produção em pequenos lotes

Marcos Marinovic Doro, M. Sc.

mmd@labmetro.ufsc.br

Programa de Pós-Graduação em Engenharia Mecânica – UFSC

Gustavo Daniel Donatelli, Dr. Eng.

gd@certi.org.br

Fundação CERTI, Centro de Metrologia e Instrumentação

Carlos Alberto Schneider, Dr. Ing.

cas@certi.org.br

Fundação CERTI, Superintendente Geral

RESUMO

A mudança freqüente no interesse dos consumidores obriga as empresas a adotar a produção em pequenos lotes em sua programação. O planejamento da inspeção é uma etapa crítica de ser realizada na produção em pequenos lotes, devido à insuficiência de informações para estabelecer a tomada de decisões de controle para a variedade de produtos. Torna-se necessário focar nos parâmetros do processo que produzem os produtos em vez de no método tradicional de medir a característica do produto a fim de controlar o processo. Na realidade, o processo que produz o produto é o responsável pela qualidade gerada. Uma vez que isto seja compreendido, volta-se o foco sobre as características do processo independentemente da variedade dos produtos. Este artigo apresenta um sistema de suporte ao planejamento da inspeção baseado em métodos probabilísticos e voltado para o controle dos parâmetros do processo. São apresentados os métodos utilizados para a construção do sistema, com destaque para mecanismos de quantificação de redes Bayesianas.

Palavras-chave: Produção em pequenos lotes. Plano de controle. Redes Bayesianas.

1 INTRODUÇÃO

O planejamento da inspeção tem por objetivo assegurar que o processo de inspeção esteja sistematizado a ponto de poder prover informações confiáveis referentes ao atendimento dos requisitos da qualidade do produto e do processo. Segundo Pfeifer (2002) e Winchell (1996), o planejamento da inspeção inclui um entendimento de e:

- O que inspecionar, p. ex., quais características do produto serão escolhidos;
- Quando inspecionar, p. ex., em qual momento durante a produção;
- Como inspecionar, p. ex., medição ou comparação com um gabarito;
- Quanto inspecionar, p. ex., inspeção 100% ou por amostragem;
- Onde inspecionar, p. ex., na linha de produção ou na sala de medição;
- Como analisar, p. ex., controle estatístico do processo.

O planejamento da inspeção tem como principal resultado o plano de inspeção, também chamado de plano de controle (IQA, 1997), que define o que deve ser inspecionado, bem como todas as decisões associadas para sua operacionalização.

Na produção em pequenos lotes, para se produzir de forma rentável, é fundamental que o planejamento da inspeção seja executado adequadamente, uma vez que a etapa de produção é muito curta (PYZDEK; KELLER, 2003). Entretanto, a grande diversidade e o lançamento contínuo de novos produtos num ambiente de produção em pequenos lotes trazem diversos problemas para o planejamento da inspeção.

A grande dificuldade do planejamento de inspeção na produção em pequenos lotes é atingir a abrangência adequada, ou seja, planejar corretamente as inspeções que serão utilizadas na produção, evitando excessos ou faltas de controles. O volume de detalhes e a falta de informações adequadas como a taxa esperada de ocorrência de defeitos e o conhecimento da configuração ótima para as variáveis do processo, tornam economicamente inviável a verificação de todos os detalhes que tangem o planejamento. Para lotes de produção unitários ou com baixa taxa de repetições este problema torna-se ainda mais crítico, pois pode não existir a oportunidade de executar um replanejamento, obrigando que se produza com a qualidade desejada desde a primeira vez (JURAN et al., 1998; MAHONEY, 1997).

Este trabalho propõe a utilização de sistemas especialistas probabilísticos, baseados no teorema de Bayes, com o objetivo de fornecer ao planejador uma visão antecipada sobre a efetividade do plano de controle em relação à qualidade. O objetivo deste sistema é corrigir a falta ou excessos de inspeção, antes mesmo de iniciar a produção, viabilizando a criação de planos de controle otimizados para a produção em pequenos lotes.

2 REDES BAYESIANAS

As redes Bayesianas são esquemas de representação de conhecimento que são utilizadas para desenvolver a base de conhecimento de um sistema especialista probabilístico. Elas possuem uma parte estrutural refletindo relações causais entre as variáveis de entrada (inputs) e a variável de saída (output) do sistema e valores de probabilidade refletindo a força da relação.

Segundo Jensen (2001), uma rede Bayesiana é um modelo matemático baseado em nós e arcos que representam, respectivamente, as variáveis de um universo $U = (A_1, A_2, \dots, A_n)$ e a dependência entre estas. A direção dos arcos, em geral, representa relações de causa-efeito entre as variáveis. Por exemplo, se houver um arco indo de um nó A para um nó B (Figura 1), assume-se que A representa uma causa de B e adota-se como nomenclatura que A é um dos pais de B; analogamente, B é um dos filhos de A. Associado ao grafo existe uma distribuição de probabilidades.

As redes Bayesianas adotam uma representação compacta onde são definidas somente as probabilidades condicionais de cada nó em relação aos seus pais. As redes Bayesianas obedecem à condição de Markov: não existe uma relação de dependência direta entre quaisquer dois nós a não ser que exista um arco entre eles na rede. A distribuição de probabilidade correspondente à rede é calculada a partir destas probabilidades condicionais:

$$P(U) = P(A_1, A_2, \dots, A_n) = \prod_{i=1}^n P(A_i | pa(A_i)), \quad (\text{JENSEN, 2001})$$

onde $P(U)$ é a probabilidade conjunta para a rede, $pa(A_i)$ são os pais do nó A_i e $P(A_i | pa(A_i))$ são as probabilidades condicionais de A_i em relação aos seus pais.

Cada nó possui um número finito, maior ou igual a dois, de categorias. As categorias, também comumente denominadas de estados, representam os possíveis valores da variável representada pelo nó. Um nó é observado quando há conhecimento sobre o estado da variável que representa o nó. Os nós observados têm grande importância no processo de inferência realizado na rede, pois, juntamente com as probabilidades condicionais especificadas para a rede, determinam as probabilidades dos nós não observados. As probabilidades condicionais da rede após a inferência são dadas por:

$$P(A_i | E), A_i \in U, \quad (\text{JENSEN, 2001})$$

ou seja, as probabilidades de cada nó, dado o conjunto de nós observados (E).

No entanto, em aplicações práticas, os valores da probabilidade conjunta $P(U)$ não são muito significativos na análise do problema modelado. De maior interesse são as probabilidades marginais de cada nó não observado. Utilizando-se a probabilidade

conjunta, podem-se obter as probabilidades marginais somando-se, para cada estado de cada variável, todas as probabilidades em que a variável encontra-se no estado desejado. Em seguida, normalizam-se as probabilidades obtidas e obtêm-se as probabilidades marginais para cada nó (SAHEKI et al., 2003). Esses conceitos são ilustrados a seguir através de um exemplo.

A Figura 1 ilustra uma rede com três nós, denominados A, B e C, antes e após a inserção de uma observação no nó B, bem como as respectivas tabelas de probabilidades para a rede.

Figura 1- Exemplo de rede Bayesiana.

A partir das tabelas acima, obtêm-se a tabela conjunta $P(A, B, C)$, contendo oito valores, dados por $P(A, B, C) = P(A) * P(B|A) * P(C|A)$:

Tabela 1- Valores de $P(A, B, C)$

$P(a_1, b_1, c_1) = 0,024$	$P(a_1, b_2, c_1) = 0,096$	$P(a_2, b_1, c_1) = 0,015$	$P(a_2, b_2, c_1) = 0,045$
$P(a_1, b_1, c_2) = 0,056$	$P(a_1, b_2, c_2) = 0,224$	$P(a_2, b_1, c_2) = 0,135$	$P(a_2, b_2, c_2) = 0,405$

Para o caso em que o nó B é observado como $B = b_2$, realiza-se um processo de inferência para os nós A e C. Para $P(a_1| B = b_2)$, por exemplo, realiza-se o seguinte cálculo:

$$P(a_1|B = b_2) = \frac{P(a_1, b_2, c_1) + P(a_1, b_2, c_2)}{P(a_1, b_2, c_1) + P(a_1, b_2, c_2) + P(a_2, b_2, c_1) + P(a_2, b_2, c_2)}$$

Como é observado que $B = b_2$, desta forma, todas as probabilidades em $P(A, B, C)$ contendo b_1 não são utilizadas. Realizando-se o processo acima para todos os estados de A e C, obtêm-se as probabilidades condicionais para cada nó, exibidas na Tabela 2:

Tabela 2- Probabilidades condicionais para cada nó

$P(a_1/ B = b_2) = 0,416$	$P(c_1/ B = b_2) = 0,183$
$P(a_2/ B = b_2) = 0,584$	$P(c_2/ B = b_2) = 0,817$

O processo de inferência realizado acima é a base da utilidade das redes Bayesianas. No entanto, existem algoritmos mais eficientes em tempo e espaço, que não exigem o cálculo de toda a tabela conjunta (JENSEN, 2001).

Portanto, as redes Bayesianas trabalham com relações causais quantificadas por valores de probabilidade condicional. A principal vantagem do raciocínio probabilístico sobre raciocínio lógico é fato de que podem tomar decisões racionais mesmo quando não existe informação suficiente para se provar que uma ação funcionará. Os sistemas baseados em redes Bayesianas são capazes de gerar automaticamente previsões ou decisões mesmo na situação de inexistência de algumas partes de informação (PEARL, 1988).

Geralmente, a rede Bayesiana é extraída de um especialista humano, que transfere seus conhecimentos do domínio de aplicação para o engenheiro de conhecimento do sistema. Porém, pesquisas vêm sendo realizadas buscando construir redes Bayesianas utilizando algoritmos capazes de estimar os valores das probabilidades bem como identificar os nós da rede a partir de bases de dados. Quando uma rede Bayesiana está ligada a uma base de dados ela torna-se adaptativa e se atualiza conforme as probabilidades estimadas nos dados armazenados, sendo chamadas de redes Bayesianas adaptativas. Outra possibilidade seria a capacidade de aprender por meio da alteração de sua topologia, podendo acrescentar ou retirar variáveis da base de conhecimento, sendo chamadas de redes Bayesianas dinâmicas (KORB; NICHOLSON, 2004).

3 MODELO DE REDE BAYESIANA PARA PRODUÇÃO EM PEQUENOS LOTES

A natureza da produção em pequenos lotes é caracterizada por uma grande diversidade de produtos. Contudo, os processos de manufatura que produzem esses diversos produtos apresentam algumas combinações singulares de máquinas, métodos, instrumentos, materiais e pessoas envolvidas com a produção. Assim, uma das abordagens possíveis de ser utilizada na produção em pequenos lotes é priorizar o monitoramento do processo ao invés do monitoramento do produto (DIVERSIFIED SYSTEMS, 2002). Ressalta-se que o aspecto chave para se atingir sucesso na produção em pequenos lotes é executar o planejamento da inspeção focado fortemente em melhorar a capacidade do processo do que a inspeção de produto.

3.1 Modelo Qualitativo da Rede Bayesiana

Sabe-se que qualquer processo apresenta variação (WINCHELL, 1996), sendo que a capacidade do processo é influenciada por essa variação e o propósito do plano de controle é indicar as ações que devem ser executadas para prevenir ou controlar esta variação. Partindo deste princípio, a topologia das redes Bayesianas foi concebida para identificar a probabilidade de um dado processo atingir um determinado nível de capacidade através dos controles aplicados ao mesmo. A Figura 2 ilustra um exemplo hipotético de processo e a respectiva topologia da rede Bayesiana proposta para auxiliar na criação do plano de controle. No modelo proposto, os nós de entrada da rede (Controle 1, 2, 3, 4,..., n) correspondem a todos os possíveis controles capazes de serem aplicados a um determinado processo. Os estados de cada nó de entrada (Controle padrão 1, 2, 3,..., n) representam os diferentes tipos de padrão configuração para um mesmo controle, ou seja, cada controle poderá variar em relação à frequência de amostragem, técnica de avaliação/medição, método de avaliação etc. O controle padrão está associado a uma linha pré-formatada para ser inserida ao plano de controle, sendo que se pode configurar um ou mais controles padrão para cada ponto de controle. O plano de controle será formado pela combinação dos diversos controles padrão. Finalmente, o nó de saída da rede (Capacidade do processo) diz respeito às faixas de índice de capacidade atingida pelo processo. A informação do nó de saída é proveniente da inspeção de produto.

Figura 2- Modelo de processo e topologia da rede Bayesiana para predição da capacidade.

A rede bayesiana será utilizada a partir da inserção de observações nos nós de entrada, de acordo com a escolha dos parâmetros para serem inseridos ao plano de controle. Ou seja, o planejador deverá selecionar o controle padrão desejado para cada ponto de controle. A partir da observação dos nós e o processo de inferência, o planejador obterá a probabilidade posterior dos demais nós da rede. O nó de saída é o que o fornecerá o maior auxílio em sua decisão, o qual mostrará a probabilidade do processo em atingir um determinado índice de capacidade a partir do plano de controle estabelecido, sendo que os demais nós também são úteis na avaliação e escolha dos controles.

3.2 Método de Quantificação da Rede Bayesiana

Um estágio posterior à criação da estrutura da rede Bayesiana é a especificação de suas probabilidades. O método para obter as probabilidades da rede está baseado em técnicas de aprendizagem. O aprendizado requer uma base de dados e um algoritmo de aprendizado. A base de dados será produzida de acordo com a aplicação do plano de controle durante a produção e a qualidade atingida pelo processo medida através da inspeção do produto. A Tabela 3 apresenta um exemplo da estrutura da base de dados utilizada para a geração das probabilidades de uma rede Bayesiana similar a da Figura 1. Nesta estrutura de base de dados, as colunas contêm os nós da rede Bayesiana relacionada à operação de processo, enquanto que as linhas correspondem aos estados dos nós, cujas informações são obtidas durante o lote de produção dos diversos produtos.

Tabela 3- Exemplo de base de dados para o aprendizado das probabilidades da rede

Lote	Produto	Controle 1	Controle 2	Controle 3	Controle 4	...	Controle n	Capacidade do processo
001	X	Controle Padrão 2	Controle Padrão 1	Controle Padrão 1	Controle Padrão 3	...	Controle Padrão 1	0,75
002	Y	Controle Padrão 2	Controle Padrão 1	Controle Padrão 3	Controle Padrão 2	...	Controle Padrão 1	0,90
003	Z	Controle Padrão 2	Controle Padrão 3	Controle Padrão 2	Controle Padrão 2	...	Controle Padrão 1	1,10
004	X	Controle Padrão 1	Controle Padrão 1	Controle Padrão 2	Controle Padrão 3	...	Controle Padrão 2	0,85
...	...	...	...	...	...	...	...	...

É possível que esta base de dados necessite ser desenvolvida de forma gradativa, na medida em que novos produtos são produzidos e novos controles estabelecidos. O importante é destacar que a base de dados registra de forma estruturada a informação da eficiência atingida com a aplicação de um conjunto de controles na produção, de forma que a informação seja reaproveitada para os lotes seguintes.

Ressalta-se que na produção em pequenos lotes cada produto difere-se dos demais em relação a seu projeto. Entretanto, uma simplificação geralmente é possível utilizando o conceito de similaridade. Essa abordagem utiliza o fato de que todos os produtos na mesma família possuem semelhanças de: requisitos de cliente, especificações de projeto, seqüência de operações, variáveis de processo, instruções de inspeção, entre outros. Utilizando este conceito é possível filtrar as informações da base de dados para a geração das probabilidades da rede para um determinado tipo de produto.

4 UMA APLICAÇÃO PRÁTICA

Com o objetivo de testar e validar os conceitos propostos num ambiente fabril, realizou-se um estudo de caso numa empresa montadora de placas eletrônicas em pequenos lotes. Uma linha de montagem de placas eletrônicas é um FMS (Sistema Flexível de Manufatura). Quando corretamente ajustada, a linha de montagem de placas eletrônicas permite uma rápida troca de um produto para o outro, o que permite produzir uma grande diversidade de produtos.

De forma generalizada, as três principais operações envolvidas na montagem das placas eletrônicas são: aplicação de pasta de solda, inserção automática de componentes e soldagem por refusão e por solda onda. Durante a realização destas operações, existem várias oportunidades de ocorrerem defeitos nos produtos. Quase a totalidade dos defeitos gerados é inspecionada por atributos, o que dificulta muito a inspeção e o controle do processo. Para prevenir ou corrigir esses defeitos requer-se um conhecimento conclusivo das relações de causa e efeito do processo de montagem. No entanto, uma inspeção 100% do produto no final da linha sempre se torna necessária. As principais técnicas de inspeção e teste de utilizadas neste processo são: inspeção manual visual (MVI), inspeção óptica automática (AOI), inspeção raio-X manual e automática (AXI), testes de circuito (ICT) e teste funcional (FT) (DORO, 2004).

Um aplicativo foi desenvolvido para operacionalizar a aplicação das redes Bayesianas durante a execução do planejamento da inspeção para o processo de montagem de placas eletrônicas. Para a realização deste aplicativo optou-se pela plataforma de desenvolvimento Delphi em conjunto com o gerenciador de base de dados relacional Firebird e o shell Netica. O shell Netica consiste de uma ferramenta computacional que permite criar a parte estrutural das redes Bayesianas, bem como o aprendizado automático das probabilidades e a execução das inferências na rede.

No aplicativo desenvolvido, vinculou-se uma rede Bayesiana específica para cada tipo operação. Por exemplo, para operação de inserção de componentes SMT foi vinculada à rede Bayesiana da Figura 3-A. Nota-se que os nós de entrada da rede referenciam-se aos controles das características de processo ou produto. O nó de saída da rede referencia aos índices de capacidade do processo, calculados neste caso em DPMO (Defeitos por Milhão de Oportunidades) (ANSI, 2002).

A - Rede antes do aprendizado

B - Rede após o aprendizado

Figura 3- Rede Bayesiana aplicada à operação de inserção de componentes SMT.

Entretanto, para que as redes Bayesianas possam ser operacionalizadas é necessário configurar suas tabelas de probabilidades condicionais (Figura 3-B). Para isto, durante as inspeções dos lotes de produção deve ser registrado na base de dados se a características controladas apresentaram-se: sob controle, fora de controle ou não foi verificada. Também deve ser informada a capacidade atingida naquele processo calculada em DPMO a partir dos defeitos encontrados no produto (Figura 4). A operação de aprendizagem é executada a partir dos dados lidos na base de dados do aplicativo e do algoritmo de aprendizado Counting-Learning (NORSYS, 1997).

Registro dos dados de processo e qualidade atingida

Volta Exibir

Volta Histórico Pessoas

Processo
Inserção automática de componentes SMT - JUKI - FC-1R

Registro
Linha: 1/29

Responsável: MMO Data: 22/2/2008 No. registro: 1

Código da PQ: 7255 Lote: 01-7255 Qualidade: 163

Qualidade (Nó de saída)
DPMO

Qualidade atingida
DPMO: 163 ppm

Capacidade do processo medida após a produção do lote

No. Reg	Lote	Código da PQ	Controle	Característica da qualidade	Especificação	Téc. Aval.	Tamanho	Frequência
1	01-7255	7255	OK	Conferência de setup da alimentação	100% correto	Visual	2	Cada início c
1	02-7255	7255	OK	Conferência de realimentação do componente	100% correto	Visual	2	Cada nova re
1	03-7255	7255	OK	Defeitos após inserção automática de componentes SMT	Manual de critéri	Inspeção vi	1 placa	Cada 1 hora
1	04-7255	7255						
1	05-7255	7255						
1	06-7255	7255						
1	07-7255	7255						
1	08-7255	7255						
1	09-7255	7255						
1	10-7255	7255						
1	11-7255	7255						
1	12-7255	7255						
1	13-7255	7255						
1	14-7255	7255						
1	15-7255	7255						
1	16-7255	7255						
1	17-7255	7255						
1	18-7255	7255						

Controles realizados durante a produção do lote

Figura 4- Registro das características de controle e capacidade do processo na base de dados.

Além dos formulários de configuração dos controles e das redes Bayesianas, desenvolveu-se um formulário para gerar uma interface mais amigável ao planejador para criar o plano de controle para cada tipo de produto (Figura 5).

Neste formulário, na medida em que os controles vão sendo selecionados pelo planejador, ou seja, os nós de entrada da rede Bayesiana vão sendo observados. O aplicativo executa as inferências na rede Bayesiana e mostra a probabilidade do processo de atingir um determinado índice de capacidade, através do nó de saída da rede. Com isto, o planejador poderá verificar o impacto de cada controle padrão e decidir se deseja inseri-lo ou não no plano de controle.

Figura 5- Interface do Sistema Especialista Probabilístico para predição da capacidade do processo

4.1 Avaliação e Análise de Desempenho

Após ser concluído o desenvolvimento do aplicativo, a próxima atividade tratou da avaliação e análise de desempenho das redes Bayesianas. Esta atividade aconteceu num período de aproximadamente dois meses durante os lotes de produção de oito produtos diferentes. Por questões de viabilidade resolveu-se focar o estudo somente nas operações de inserção automática de componentes SMT. A coleta dos dados de defeitos no produto para o cálculo da capacidade de processo ocorreu após a soldagem por refusão, utilizando diferentes técnicas de inspeção e testes (MVI, AOI, ICT e FT). Já com relação aos dados de processo, todos os controles definidos no plano de controle foram executados pelos operadores das máquinas e auditados pelo inspetor da qualidade. Essas informações foram inseridas na base de dados da qualidade sempre que um lote de produção era concluído (FIGURA 4).

Os dados coletados foram utilizados para aprendizagem das probabilidades da rede Bayesiana. Em seguida, com o auxílio do aplicativo, os planos de controle foram estabelecidos para os novos lotes a partir dos resultados de previsão da capacidade do

processo indicados pelas redes Bayesianas. Esta capacidade de processo foi verificada durante a produção com a execução do plano de controle. A Tabela 4 mostra um resumo dos resultados atingidos.

Tabela 4- Comparação da qualidade prevista versus qualidade atingida

		Máquinas de inserção automática de componentes SMT				
		JUKI FX-1	JUKI FX-1R	FUJI CP-6	FUJI IP-III	GSM DT255
Probabilidade prevista em atingir cada nível de qualidade	Menor que 100 DPMO	58,95%	75,45%	9,09%	50%	64,81%
	De 100 a 500 DPMO	33,16%	17,86%	68,18%	44,44%	18,52%
	De 500 a 1000 DPMO	6,44%	3,57%	18,18%	1,85%	11,11%
	Maior que 1000 DPMO	6,44%	3,57%	4,54%	3,70%	5,55%
Qualidade atingida nos lotes de produção	01	57 DPMO	169 DPMO	61 DPMO	327 DPMO	0 DPMO
	02	38 DPMO	149 DPMO	69 DPMO	862 DPMO	0 DPMO
	03	41 DPMO	191 DPMO	34 DPMO	1348 DPMO	1035 DPMO
	04	33 DPMO	179 DPMO	67 DPMO	1004 DPMO	0 DPMO
	05	11 DPMO	244 DPMO	113 DPMO	1242 DPMO	0 DPMO
	06	7 DPMO	94 DPMO	63 DPMO	1539 DPMO	0 DPMO
	07	13 DPMO	74 DPMO	33 DPMO	2320 DPMO	420 DPMO
	08	17 DPMO	57 DPMO	42 DPMO	1746 DPMO	527 DPMO
	09	29 DPMO	51 DPMO	59 DPMO	1591 DPMO	373 DPMO
	10	55 DPMO	49 DPMO	99 DPMO	1387 DPMO	0 DPMO
	11	12 DPMO	81 DPMO	59 DPMO	587 DPMO	0 DPMO
	12	29 DPMO	91 DPMO	112 DPMO	1486 DPMO	607 DPMO
	13	43 DPMO	112 DPMO	108 DPMO	549 DPMO	684 DPMO
	14	44 DPMO	77 DPMO	74 DPMO	892 DPMO	0 DPMO
<div> <div></div> Processo sob causa especial </div> <div> <div></div> Placa com projeto inadequado (ilhas desiguais) </div>						

A partir dos dados mostrados na Tabela 4 observa-se que, com exceção da máquina JUKI FX-1R que operou sob causa especial em alguns lotes e da máquina FUJI IP-III em que o projeto da placa estava inadequado para o processo, em grande

parte dos lotes de produção a qualidade atingida foi de acordo a probabilidade prevista. Assim sendo, para o processo de montagem de placas eletrônicas pode-se verificar que as redes Bayesianas obtiveram êxito em sua aplicação, mostrando ser uma ferramenta viável para ser empregada na produção em pequenos lotes. A rede Bayesiana permitiu que dados históricos coletados de lotes anteriores fossem usados para obter uma previsão da capacidade do processo na produção de novos produtos.

No entanto, a partir dos dados analisados, foi constatado neste estudo que a previsibilidade aconteceu sob certas condições:

- É necessário usar dados coletados por sistemas de medição equivalentes: dados coletados de sistema de medição diferentes podem gerar resultados incompatíveis, pois o sistema de medição influencia diretamente no resultado da medição, ou seja, a qualidade produzida pelo processo pode ser bem diferente da qualidade percebida por sistemas de medição diferentes;
- É necessário usar dados históricos de produtos semelhantes: produtos que diferem em relação aos materiais, componentes, sequência de operações etc., podem resultar um nível qualidade totalmente diferente perante a um mesmo processo;
- Não podem existir desvios no projeto do produto: o projeto do produto influi muito no resultado do processo e caso o projeto não esteja adequado, os resultados são imprevisíveis;
- Deve haver uma repetitividade e reprodutibilidade em relação aos controles: caso os controles estabelecidos no plano de controle não sejam executados da mesma forma pelos operadores ou máquina, os dados coletados durante a produção não serão confiáveis;
- As causas especiais devem ser analisadas, pois podem aumentar ou reduzir drasticamente o nível de qualidade de um processo. Portanto, deve-se fazer uma análise para verificar se o aprendizado das probabilidades da rede Bayesiana irá englobar ou descartar os dados contaminados com causas especiais. Neste caso, por exemplo, pode-se englobar um número considerável de dados no quais as causas especiais são inerentes ou pode-se se criar artifícios para separar os dados contendo as causas especiais.

5 CONCLUSÕES

A qualidade dos produtos manufaturados depende de muitas variáveis. Algumas delas podem ser controladas enquanto que outras são fontes reais de variação e não podem ser manipuladas. Isto torna muito difícil de prever os potenciais problemas da qualidade nos produtos durante a produção, especialmente na produção em pequenos lotes.

Neste trabalho apresentou-se um modelo e a implantação de um Sistema Especialista baseado em redes Bayesianas para dar suporte ao planejamento da inspeção na produção em pequenos lotes. No modelo proposto, as redes Bayesianas são estruturadas para prever da qualidade gerada por um processo. Esta predição acontece a partir de dados históricos adquiridos durante a produção dos diversos produtos manufaturados num dado processo.

Um sistema de predição da qualidade deve ser capaz de inferir informações sobre as características críticas e qualidade final do produto, baseado na avaliação de múltiplos atributos de qualidade e variáveis de processos. Diferentes abordagens têm sido empregadas com este propósito, as quais podem estar fundamentadas em técnicas estatísticas (p. ex. análise de regressão) ou não (p. ex. redes neurais, redes Bayesianas e algoritmos genéticos). O grande desafio destes métodos é construir um modelo que descreva a relação entre as variáveis de entrada e saída do sistema de produção. Tal modelo deve ser capaz de se adaptar as mudanças dos estados processos e também as influências não mensuráveis.

Optou-se neste trabalho pela utilização das redes Bayesianas para desenvolver um sistema de predição da qualidade devido à simplicidade na forma de representação de conhecimento e principalmente pelo fato de possuírem a possibilidade de adaptar automaticamente sua base de conhecimento a partir de dados históricos. Através de uma aplicação prática em um processo de montagem de placas eletrônicas em pequenos lotes pode-se verificar que, quando certas condições são respeitadas, as redes Bayesianas fornecem estimativas corretas sobre a qualidade que será atingida durante a produção, mostrando ser uma ferramenta poderosa e prática para a produção em pequenos lotes.

ABSTRACT

With consumers' tastes changing frequently, companies are forced to adopt small batch production schedules. Inspection planning is a critical phase in the small batch production due to lack of sufficient data to establish control decisions for product variety. We need to focus on the actual process parameters that produce the product rather than the traditional method of measuring a product characteristic to control the process. It is actually the process that produces a product that is responsible for the quality of the output. Once we realize this, we start focusing on process characteristics irrespective of which variety of product it produces. This paper presents an inspection planning decision support system based on probabilistic methods and focused on the process parameters control. The methods used for the construction of the system are introduced, with emphasis on mechanisms to quantify Bayesian networks.

Keywords: Small batch production. Control plan. Bayesian networks.

REFERÊNCIAS

PFEIFER, T. **Production Metrology**. German: Oldenbourg Wissenschaftsverlag, 2002. 421p.

WINCHELL, W. **Inspection and Measurement in Manufacturing, keys to process planning and improvement**. USA: Society of Manufacturing Engineers, 1996. 197p.

SÃO PAULO (Estado) INSTITUTO DA QUALIDADE AUTOMOTIVA. **Planejamento Avançado da Qualidade do Produto e Plano de Controle - APQP**: manual de referência. São Paulo, 1997. 101p.

PYZDEK, T.; KELLER, P. A. **Quality Engineering Handbook**. 2. edition, New York: Marcel Dekker, 2003. 732 p.

JURAN, J. M.; GODFREY, A. B.; HOOGSTOEL, R. E.; SCHILLING, E. G. **Juran's Quality Handbook**. 5. edition., USA: McGraw-Hill, 1998. 1730p.

MAHONEY, R. M. **High-Mix Low-Volume Manufacturing**. New Jersey: Prentice Hall, 1997. 222p.

SAHEKI, A. H.; SHAROVSKY, R.; COZMAN, F. G.; COUPÉ, V. Construção de uma rede Bayesiana aplicada ao diagnóstico de doenças cardíacas. In: ENCONTRO NACIONAL DE INTELIGÊNCIA ARTIFICIAL, 2003, Campinas. **Anais**. . . Campinas, 2003. 10 p.

JENSEN, F.V. **Bayesian Networks and Decision Graphs**. New York: Springer-Verlag, 2001. 294p.

PEARL, J. **Probabilistic Reasoning in Intelligent Systems: Networks of Plausible Inference**. San Mateo: Morgan Kaufmann, 1988. 552p.

KORB, K. B.; NICHOLSON, A. E. **Bayesian Artificial Intelligence** USA: CRC Press, 2004. 366p.

DIVERSIFIED SYSTEMS. **SMT Process Capability for Small Lots**. Indianapolis, v. 2, n. 2, 2002. Disponível em:
<<http://www.divsys.com/Newsletter/Archives/ViewArchives.asp>> Acesso em: 28 maio 2008.

DORO, M. M. **Sistemática para implantação da garantia da qualidade em empresas montadoras de placas de circuito impresso**. 2004, 149 f. Dissertação (Mestrado em Metrologia Científica e Industrial)- Universidade Federal de Santa Catarina, Florianópolis, 2004.

VIRGINIA (Estado). AMERICAN NATIONAL STANDARDS INSTITUTE. **IPC-9261: In-**

Process DPMO and Estimated Yield for PWAs, Virginia, 2002. 14p.

Norsys Software Corporation. Netica Application, Version 4.09. Vancouver, 1997.
Disponível em: <<http://www.norsys.com/download.html>>. Acesso em: 2 junho 2009.