

CORREÇÃO DA FORMA DE FIGURAS GEOMÉTRICAS UTILIZANDO REDE NEURAL ARTIFICIAL

José Homero Feitosa Cavalcanti

Curso de Pós-Graduação em Engenharia Mecânica - CT-UFPB - Campus I - CEP: 58059 - 900 – João Pessoa – PB, Fax: 2167186. e-mail: zevhom@uol.com.br

João Bosco de Aquino Silva

Curso de Pós-Graduação em Engenharia Mecânica - CT-UFPB - Campus I - CEP: 58059 - 900 – João Pessoa – PB, Fax: 2167186. e-mail: jbosco@ufpb.br

José Carlos de Lima Júnior

Curso de Pós-Graduação em Engenharia Mecânica - CT-UFPB - Campus I - CEP: 58059 - 900 – João Pessoa – PB, Fax: 2167186. e-mail: limajrcarlos@hotmail.com

Resumo. *Existem diferentes métodos de se obter a forma de objetos (ou peças) tridimensionais. Os métodos principais são os baseados nas fotografias dos objetos, os que utilizam Máquinas de Medição por Coordenada (MMC), e os que utilizam manipuladores robóticos para tatear toda a superfície da peça. Os dados obtidos da peça, utilizando-se uma MMC, devem ser processados utilizando programas do tipo CAD para a análise e desenho do objeto. Considere que uma peça é posta na MMC para ser medida e os dados da geometria (ou figura) de um determinado elemento da peça são determinados pela máquina. Por exemplo, na medição de uma peça na forma de um círculo, pode ocorrer que a máquina por algum motivo informou uma coordenada do círculo de maneira incorreta, desta forma é necessária uma metodologia capaz de corrigir tais erros. Portanto neste trabalho serão apresentados resultados obtidos de simulação de um sistema inteligente baseado em redes neurais artificiais capaz de corrigir erros de medições.*

Palavras-chaves: *Redes neurais artificiais, figuras geométricas, erros de medições.*

1. INTRODUÇÃO

O conceito de projeto, fabricação e inspeção dos modernos produtos manufaturados têm mudado devido a utilização de novas tecnologias. Dentre estas tecnologias se destacam as máquinas-ferramenta comandadas numericamente por computador, projeto associado por computador (CAD) e fabricação assistida por computador (CAM). O controle dimensional das peças manufaturadas é imprescindível para garantir que as tolerâncias especificadas no projeto sejam atendidas. Assim, um sistema de inspeção capaz de atender às exigências da manufatura atual deverá apresentar os seguintes requisitos:

- Rapidez compatível com a velocidade de produção;
- Capacidade de controlar geometrias complexas;
- Apresentar incerteza de medição compatível com as tolerâncias da peça;
- Ser flexível para controlar grande diversidade de geometrias;

As técnicas de medições convencionais não são capazes de atender estas exigências. Neste contexto, a medição por coordenadas evoluiu nas últimas duas décadas e hoje é a tecnologia que melhor atende aos requisitos da manufatura moderna através das Máquinas de Medições por Coordenadas (MMC's). Este tipo de equipamento é amplamente utilizado por apresentar os resultados da medição de forma precisa. Mesmo apresentado tais vantagens, as MMC's necessitam de uma verificação periódica para realizar uma avaliação das qualidades metrológicas deste equipamento. Caso, uma MMC esteja fora das especificações do fabricante, então deve ser efetuada a sua calibração. Quando uma peça é levada para inspeção a mesma pode apresentar erros em suas medidas, ou seja, as dimensões da peça estão fora das tolerâncias especificadas no projeto. Estes erros podem ser originados tanto da peça que foi produzida de forma incorreta, bem como, oriundos da própria máquina onde estão sendo realizadas as medições. Segundo Lima Jr (2003), as principais fontes de erros de uma MMC são: condições ambientais; apalpador; unidade de controle; peça; software; sistema de medição de deslocamento e sistema de medição de coordenadas.

Estas fontes de erros podem provocar a rejeição de peças com dimensões dentro das especificações de projeto, bem como a aceitação de peças fora das tolerâncias. Alguns autores têm dado atenção a utilização da rede neural na correção de figuras complexas (Kawashima, 1996; Humelhart et al, 1986 e Yoshina et al, 1996). Este trabalho tem como principal objetivo apresentar uma aplicação de redes neurais multi-camadas (RMMC) para a correção de figuras geométricas representadas por círculos. Como demonstrado por Kurkova (1995), a utilização das RNMC baseia-se na sua capacidade de representar qualquer função contínua. Observe-se que as coordenadas do círculo, descritas usando funções trigonométricas (seno e cosseno), são adequadas para serem utilizadas como entrada da rede neural por representarem funções contínuas.

Neste trabalho inicialmente apresentam-se e as características básicas de figuras geométricas. Após uma descrição sucinta das redes neurais artificiais, propõe-se uma arquitetura de uma RNMC capaz de corrigir as coordenadas de uma figura geométrica. A seguir, apresentam-se resultados obtidos de simulação da correção de círculos utilizando a RNMC. Finalmente, conclui-se este trabalho com comentários e sugestões sobre o método desenvolvido para a correção das coordenadas de figuras geométricas.

2. AS FIGURAS GEOMÉTRICAS

A construção de figuras geométricas bidimensionais pode ser feita com dois vetores representando as suas coordenadas x e y. A Equação (1) representa um círculo de raio r.

$$r = \sqrt{x^2 + y^2} \quad (1)$$

As coordenadas x e y podem ser representadas pelas Eq. (2) e (3), respectivamente, com f representando o ângulo ao longo do círculo.

$$x = r \cdot \cos(f) \quad (2)$$

$$y = r \cdot \sin(f) \quad (3)$$

Na parte superior da Fig. (1) apresenta-se um círculo de raio unitário traçado a partir das coordenadas x e y (abscissa x e ordenada y) obtidas para 17 ângulos f consecutivos ($\phi=0, 360/17, 2*360/17\dots$). Na parte inferior da Fig. (1) apresentam-se as curvas de x e y (abscissa ϕ) obtidas com as Eq. (2) e Eq. (3), respectivamente. Na parte superior da Fig. (2) apresenta-se um círculo corrompido de

raio unitário traçado a partir das coordenadas x e y . Os círculos corrompidos foram construídos com valores aleatórios de amplitude máxima igual a 0.1 adicionados aos valores corretos das coordenadas x e y .




Figura 1. Círculo ideal




Figura 2. Círculo com falhas

3. REDE NEURAL ARTIFICIAL

A rede neural artificial é um sistema de neurônios ligados por conexões (chamada conexões sinápticas ou pesos). Os neurônios são agrupados em neurônios de entrada representados pelos que recebem estímulos do meio externo, neurônios internos ou hidden (ocultos) e neurônios de saída, que se comunicam com o exterior. Em outras palavras pode-se dizer que uma rede é composta por várias unidades de processamento, cujo funcionamento é bastante simples. Essas unidades, geralmente são conectadas por canais de comunicação que estão associados a determinados pesos. As unidades fazem operações apenas sobre seus dados locais, que são entradas recebidas pelas suas conexões. O comportamento inteligente de uma rede neural artificial vem das interações entre as unidades de processamento da rede.

A maioria dos modelos de redes neurais possui alguma regra de treinamento, onde os pesos de suas conexões são ajustados de acordo com os padrões apresentados. Em outras palavras, elas aprendem através de exemplos. As arquiteturas das redes neurais são tipicamente organizadas em camadas, como mostra a Fig. (3). A rede neural passa por um processo de treinamento a partir dos casos reais e numéricos conhecidos, adquirindo, a partir daí, a sistemática necessária para executar adequadamente o processo desejado dos dados fornecidos. Sendo assim, a rede neural é capaz de extrair regras básicas a partir de dados reais, diferindo da computação programada, onde é necessário um conjunto de regras rígidas pré-fixadas e algoritmos.

A propriedade mais importante das redes neurais é a habilidade de aprender de seu ambiente e com isso melhorar seu desempenho. Isso é feito através de um processo iterativo de ajustes aplicado a seus pesos, o treinamento. Haykin (2001), apresenta que o aprendizado ocorre quando a rede neural atinge uma solução generalizada para uma classe de problemas.

Denomina-se algoritmo de aprendizado a um conjunto de regras bem definidas para a solução de um problema de aprendizado. Existem muitos tipos de algoritmos de aprendizado específicos para determinados modelos de redes neurais, estes algoritmos diferem entre si principalmente pelo modo como os pesos são modificados.




Figura 3. Uma rede neural multicamadas (RNMC)

4. OS CÍRCULOS E A RNMC

A idéia central deste trabalho é treinar duas RNMC(17,20,17) (17 neurônios do tipo linear na camada de entrada, 20 neurônios do tipo sigmóide na camada escondida e 17 neurônios do tipo tangente hiperbólico na camada de saída) com valores de entrada e de saída referentes à coordenada x e

a coordenada y da figura. Utilizaram-se valores das coordenadas de círculos não corrompidos com erros para o treinamento da RNMC. Logo após o treinamento os valores das coordenadas modificados aleatoriamente serão colocados nas entradas das duas RNMC(17,20,17) que apresentarão nas suas saídas os valores corretos das coordenadas. Foram utilizados os valores corretos das coordenadas x e y do círculo para o treinamento da RNMC(17,20,17).

A RNMC(17,20,17) foi treinada durante 100 iterações utilizando as coordenadas de um círculo de raio unitário. Logo após o treinamento da RNMC, alguns valores das coordenadas corrompidos por erros foram colocados na entrada da RNMC(17,20,17) (ver as coordenadas da Fig. (2)). A saída da RNMC apresentou um conjunto de coordenadas x e y com valores próximos aos esperados, os valores foram visualmente iguais aos apresentados na Fig. (1). Definiu-se o erro como a diferença entre o valor da coordenada do círculo ideal subtraído do valor da coordenada fornecido na saída da RNMC. Calculou-se a somatória do erro ao quadrado e obteve-se $\Sigma \text{erro}^2 = 0.0012$. A seguir verificou-se a capacidade de correção da RNMC para diversos valores do módulo do sinal aleatório adicionado aos valores ideais das coordenadas do círculo. Na Tabela (1) apresentam-se os resultados obtidos para diferentes valores de amplitude do sinal aleatório. A seguir, devido ao sucesso obtido no treinamento da RNMC com as coordenadas de um único círculo, decidiu-se treinar a RNMC(17,20,17) com um conjunto de coordenadas x e y correspondentes a dez círculos com raios crescentes (0.1;0.2;...;.9 e 1.).

Tabela 1. Valores do erro quadrático para diferentes amplitudes para um único círculo

Máximo do sinal aleatório	Σerro^2
0.1	0.0012
0.2	0.0021
0.3	0.0033
0.4	0.0055

Na simulação foram usados dois conjuntos de dados. O primeiro conjunto de dados é gerado a partir das equações padrões dos círculos. Na parte superior da Fig. (4) apresentam-se os círculos gerados com as Eq.(2) e Eq.(3). Na parte inferior da Fig (4) apresentam-se as curvas referentes aos 10 conjuntos de pontos das coordenadas x e y dos círculos.

O segundo conjunto de dados é composto por círculos corrompidos (ver a parte superior da Fig. (5)). Os círculos corrompidos foram construídos com valores aleatórios de amplitude máxima igual a 0.1 adicionados aos valores corretos das coordenadas x e y. Na parte inferior da Fig. (5) apresentam-se as curvas referentes aos 10 conjuntos de pontos das coordenadas x e y dos círculos.

A seguir foi feita a aplicação das coordenadas dos círculos ideais nas duas RNMC(17,20,17). Na Figura (6) apresenta-se a curva do índice de desempenho obtida para o treinamento da RNMC(17,20,17) da coordenada x durante 1000 iterações. O índice de desempenho utilizado foi $I = 1/E^2$, com E definido como a diferença entre os valores da coordenada x do círculo e os valores das saídas da RNMC(17,20,17). Observa-se que após 800 iterações o valor do índice de desempenho se aproxima de zero.

Na parte superior da Fig. (7) apresentam-se os círculos obtidos na saída da RNMC(17,20,17) utilizando como entrada os valores das coordenadas x e y dos círculos corrompidos. Na parte inferior da Fig. (7) apresentam-se as curvas das coordenadas y dos círculos obtidos na saída da RNMC(17,20,17) (caracter '+') comparados com a coordenadas ideais. Observe-se que a RNMC(17,20,17) aprendeu corretamente a forma dos círculos. Calculou-se a somatória do erro ao quadrado para os dez círculos e obteve-se $\Sigma \text{erro}^2 = 0.0468$. Na Tabela (2) apresentam-se os resultados obtidos para diferentes valores de amplitude do sinal aleatório.




Figura 4. Círculos ideais




Figura 5. Círculos corrompidos

Tabela 2. Valores do erro quadrático para diferentes amplitudes para vários círculos

Máximo do sinal aleatório	Σerro^2
0.1	0.0468
0.2	2.0414
0.3	14.7648
0.4	51.1559




Figura 6. Índice de desempenho




Figura 7. Círculos obtidos com a RNMC

5. CONCLUSÃO

Neste trabalho apresentou-se um método para a correção de figuras geométricas de duas dimensões. O método é baseado na análise isolada de cada uma das dimensões utilizando redes neurais artificiais. Usando-se este método mostrou-se que as redes neurais artificiais multicamadas podem ser usadas na correção de figuras geométricas de uma forma satisfatória.

A configuração da RNMC utilizada foi escolhida a partir de testes de várias configurações de entrada e saída. Observou-se que caso fossem utilizados mais pontos das coordenadas dos círculos a rede neural aprenderia mais rapidamente as coordenadas dos círculos (até um certo limite).

Foram feitas tabelas para a análise da aprendizagem da RNMC. Analisando-se a Tabela (1) vê-se que a RNMC se polariza sobre o círculo treinado, ela fica praticamente imune às variações nas coordenadas dos círculos. Analisando-se a Tabela 2 vê-se que a RNMC fica muito sensível às variações nas coordenadas dos círculos.

Pretende-se experimentar este método na análise de outras figuras geométricas do tipo elipses, espirais, etc.

Nas simulações foi usado o ambiente MATLAB para a construção dos círculos ideais e com falhas e para o treinamento das redes neurais artificiais multicamadas.

6. REFERÊNCIA

- Haykin, S., 2001. “Redes neurais: princípios e prática”, 2a. edição, Bookman, Porto Alegre.
- Hummelhart, D. E., Hinton, G. E. and Williams, R. J., 1986, “Learning Representations by back-Propagating Errors”, *Nature* 323, 1986, pp.533-536.
- Lima Jr, J. C., 2003, “Determinação da planeza de superfícies metrológicas assistida por computador”, Dissertação de mestrado, CPGEM-UFPA.
- Kawashima, S. and Ishikawa, M., 1996, “Locally Shift Invariant and Globally Location dependent Recognition of Complex Figure sby Neural Networks”, *Methodologies for the Conception, Desing and Applications of Intelligent Systems Proceedings of IIZUKA*, pp. 478-481.
- Kurkova, V., 1995, “Kolmogorov’s Theorem”, publicado em *Brain Theory and Neural Networks*, Editado por Arbib, M. A., The MIT Press, London, England, 1995.
- Yoshina, T., Nagayama, I. and Akamatsu, N., 1996, “The Learning Capability of Cyclic activation BP For Two-Spirals Problems”, *Methodologies for the Conception, Desing and Applications of Intelligent Systems Proceedings of IIZUKA*, pp. 684-687.

USING ARTIFICIAL NEURAL NETWORK FOR CORRECTION OF OBJECT GEOMETRIC FORMS

José Homero Feitosa Cavalcanti

Curso de Pós-Graduação em Engenharia Mecânica - CT-UFPB - Campus I - CEP: 58059 - 900 – João Pessoa – PB, Fax: 2167186. e-mail: zevhom@uol.com.br

João Bosco de Aquino Silva

Curso de Pós-Graduação em Engenharia Mecânica - CT-UFPB - Campus I - CEP: 58059 - 900 – João Pessoa – PB, Fax: 2167186. e-mail: jbosco@ufpb.br

José Carlos de Lima Júnior

Curso de Pós-Graduação em Engenharia Mecânica - CT-UFPB - Campus I - CEP: 58059 - 900 – João Pessoa – PB, Fax: 2167186. e-mail: limajrcarlos@hotmail.com

Abstract. There are different methods to obtain the geometric form of three-dimensional workpieces and object such as: machine vision, robotic systems and co-ordinate measuring machines (CMMs). The data points, measured from existing object, should be processed by using a CAD system for feature-curve fitting in reverse engineering. It is worth noting that the original measured points can present irregular format and unequal distribution and lack of appropriate segmentation. Therefore, it is difficult to fit into a curve in CAD systems. The purpose of this work is to present simulation results of a intelligent system based on artificial neural network which was developed to correct measurement errors during the probing process in CMMs.

Key - words : Artificial neural network, geometric forms, measurement errors.