



Instrumentação de um Manipulador Paralelo com Elos Flexíveis: uma aplicação de Fusão Sensorial utilizando Redes Neurais Artificiais

Fábio Lúcio Félix, Escola de Engenharia de São Carlos, felixlfbio@gmail.com

Guilherme Serpa Sestito, Escola de Engenharia de São Carlos, guilhermesestito@gmail.com

Maíra Martins da Silva, Escola de Engenharia de São Carlos, mairams@sc.usp.br

Resumo. Os manipuladores cinemáticos paralelos (PKMs) com elos flexíveis além de apresentarem maiores relações velocidade/aceleração, capacidade de carga, rigidez e compactação quando comparados aos manipuladores seriais, também possuem melhor desempenho dinâmico e eficiência energética. No entanto, esta abordagem pode produzir vibrações que requerem a implementação de controle no espaço de junta baseado em modelo ou estratégias de controle de espaço de tarefa. Por este motivo, estudos sobre o uso de sensores redundantes têm sido realizados para obter dados relevantes para PKM com elos flexíveis. Dados experimentais de um 3RRR planar são extraídos usando codificadores, extensômetros e uma câmera durante a execução de tarefas pré-determinadas. Uma Rede Neural Artificial utilizando uma topologia de Perceptron Multicamadas é utilizada para estimar a pose do efetuador do manipulador. Esta estimativa pode ser usada para melhorar modelos dinâmicos ou para implementar estratégias de controle de espaço de tarefas.

Palavras chave: Manipuladores Cinemáticos de Cadeia Paralela. Estimativa de Posição. Fusão Sensorial. Rede Neural Artificial. Instrumentação.

1. INTRODUÇÃO

O uso de manipuladores cinemáticos paralelos tem se mostrado uma alternativa promissora em relação aos modelos padrão de arquiteturas robóticas devido à sua leveza, rigidez, capacidade de carga, altas taxas de velocidade / aceleração e compactação (Merlet, 2006). Por este motivo, esta configuração cinemática pode ser uma alternativa para o projeto de manipuladores robóticos com eficiência energética (Yan Li and Bone, 2001; Ruiz *et al.*, 2018). Porém, sua viabilidade requer a superação de algumas dificuldades práticas. Dentre essas questões, podemos citar a presença de singularidades em seu espaço de trabalho (Merlet, 2006) e a complexidade de sua estratégia de controle (Paccot *et al.*, 2009). Essa complexidade está presente nas estratégias de controle, tanto no espaço de tarefa quanto no espaço das juntas. Por um lado, as estratégias de controle do espaço das juntas requerem o cálculo do modelo cinemático inverso, o que é complicado e demorado para manipuladores de cadeia cinemática paralela. Por outro lado, as estratégias de controle do espaço de tarefas requerem a medição da pose do efetuador do manipulador por meio de técnicas baseadas em visão computacional e algoritmos de processamento de imagem (Bellakehal *et al.*, 2011).

Alguns autores propõem o uso de redundância para superar esses problemas técnicos. Por exemplo, a presença de singularidades pode ser reduzida usando redundância cinemática (Wu *et al.*, 2010; de Carvalho Fontes *et al.*, 2018, 2021), e o uso de redundância de medição pode diminuir a complexidade da estratégia de controle. Redundância de medição, que corresponde à obtenção de mais medições do que graus de liberdade para o manipulador (Muller, 2008), é usada por Zubizarreta *et al.* (2012) para aquisição mais precisa da pose do efetuador de um manipulador planar 3RRR, onde (R) descreve uma junta ativa e (RR) duas juntas passivas. Uma estratégia de *feedback* redundante no espaço da junta e de tarefas é proposta por Mohan *et al.* (2017) usando sensores apropriados. Devido à redundância de medição desta abordagem, o erro real dos deslocamentos da junta é calculado, melhorando o desempenho do controle. Uma estratégia semelhante foi proposta por Colombo *et al.* (2019) usando uma câmera de taxa limitada.

O desempenho dinâmico e a eficiência energética desses manipuladores também podem ser melhorados reduzindo a inércia de seus componentes móveis (Nabat *et al.*, 2005; Zhang *et al.*, 2015). No entanto, a redução da inércia de seus componentes aumenta a flexibilidade de toda a estrutura, dificultando o projeto do sistema de controle devido à complexidade dos modelos cinemáticos e dinâmicos tratados em (Zhang *et al.*, 2015; Wang *et al.*, 2009), e aos rígidos requisitos de técnicas baseadas na visão. Portanto, redundância de medição e estratégias de metamodelagem também podem ser uma alternativa para implementação de controladores para este tipo de sistema.

A abordagem básica para técnicas de metamodelagem é construir aproximações que irão fornecer uma resposta eficiente e uma relação funcional entre as variáveis de entrada e saída em análise (Simpson *et al.*, 2001). Para este trabalho, a pose do efetuador do manipulador paralelo 3RRR com elos flexíveis, representado na Fig. 1, é estimada usando os dados adquiridos pelos *encoders* e extensômetros. A primeira etapa para a realização dessa estimativa foi a aquisição dos conjuntos de dados de treinamento e teste durante a execução de várias tarefas predefinidas. A segunda etapa foi selecionar o metamodelo apropriado para representar esses dados adquiridos. Um algoritmo de Rede Neural Artificial (RNA) é investigado uma vez que esta metodologia é bem conhecida e apresenta bons resultados para aproximação de



2. MATERIAIS E MÉTODOS




Figura 1. Protótipo 3RRR com elos flexíveis.

funções (Haykin, 2009). Essa RNA pode ter uma ou várias camadas de neurônios, também chamadas de *perceptron*. Para *perceptrons* com mais de uma camada, chamados de *Perceptron Multicamadas* (PMC), o processo de treinamento é baseado no algoritmo *Backpropagation* (da Silva *et al.*, 2017). A terceira etapa, por fim, é realizar o procedimento de treinamento e teste do metamodelo construído. Foram avaliadas duas situações para o número total de dados utilizados para a construção da rede. No primeiro caso são utilizados todos os seis dados dos extensômetros e três de *encoders*, enquanto que no segundo caso são utilizados apenas três dados de extensômetros relativos aos elos que estão acoplados às juntas ativas e três de *encoders*. Com isso, são construídas duas redes neurais, a primeira com nove medições adquiridas dos sensores e a segunda com seis medições, com o objetivo de realizar a estimativa da postura, coordenadas x , y e α , do efetuador do manipulador na Fig. 1.

2. MATERIAIS E MÉTODOS

2.1 Redes Neurais Artificiais

Uma arquitetura de rede neural artificial (RNA) é definida como a maneira como seus vários neurônios estão dispostos uns com os outros. Esses arranjos são estruturados por meio de conexões sinápticas de neurônios. A topologia de uma rede neural, com uma arquitetura já definida, são as diferentes formas de composição que pode assumir (da Silva *et al.*, 2017). As principais arquiteturas de uma rede neural podem ser divididas em redes *feedforward* de camada única, redes *feedforward* multicamadas (ver Fig. 2) e redes recorrentes (Haykin, 2009).

A arquitetura escolhida para este trabalho foi de um PMC, que é uma rede neural que conecta uma entrada, uma saída e camadas ocultas. A Fig. 2 ilustra um MLP com p entradas, q saídas e uma única camada oculta com L neurônios. Os dados de entrada são compostos pela pose estimada do efetuador $\mathbf{X} = [x \ y \ \alpha]^T$ e as medições dos extensômetros ($p = 9$), descritos como f_i onde $i = 1 \dots p$ na Fig. 2. A pose do efetuador é estimada usando o modelo cinemático do 3RRR considerando elos rígidos e os dados medidos dos *encoders* $\Theta = [\theta_1 \ \theta_2 \ \theta_3]^T$. Este modelo está resumido na Seção 3.1.

A saída e as camadas ocultas são compostas de neurônios. A entrada para os neurônios das camadas oculta e de saída, descrita por $U = * u_j$ onde $*$ pode ser 1, 2 ou o de acordo com a camada e j pode variar de acordo ao número de neurônios da camada, é composto por uma soma ponderada. A saída desses neurônios, descritos por $* y_j$ ou e_j para as camadas ocultas ou para a camada de saída, é resultante da seguinte função de ativação do tipo tangente hiperbólica:

$$\sigma(U) = \frac{1 - e^{-\beta U}}{1 + e^{-\beta U}}. \quad (1)$$

O número de neurônios na camada oculta está diretamente relacionado à capacidade de aprendizado da rede. Geralmente, duas camadas intermediárias tratam de problemas não convexos e não contínuos, sendo amplamente aplicadas em problemas de engenharia da Silva *et al.* (2017). O algoritmo de aprendizado supervisionado para treinamento, *Levenberg-Marquardt Backpropagation* ajusta os pesos sinápticos usados para derivar as entradas dos neurônios. Neste procedimento, os dados são separados entre conjuntos de treinamento e teste. O primeiro é usado para o processo de

aprendizagem da RNA e o último para a verificação de desempenho do estimador. O algoritmo de treinamento consiste em minimizar o erro entre as saídas do conjunto de dados de treinamento (as medições reais da câmera) e a camada de saída. Além disso, foi realizada uma análise consistente em relação aos erros associados aos subconjuntos de teste e treinamento para superar situações de subfitting e overfitting. Essa análise é necessária para evitar que o algoritmo de aprendizado opte por usar um número maior de neurônios enquanto a razão entre o erro do subconjunto de teste e treinamento aumenta.




Figura 2. Ilustração de um PMC com uma única camada de neurônios escondida.

2.2 Manipulador Paralelo 3RRR Planar

Nesta seção, o protótipo experimental é descrito. Em seguida o modelo cinemático do 3RRR é apresentado.

2.2.1 Protótipo Experimental

Nesta seção, a comunicação e instrumentação do protótipo 3RRR são descritas. Os motores que realizam os deslocamentos lineares δ_i , ilustrados na Fig. 3(a), não são abordados neste trabalho, portanto as juntas relacionadas aos motores $M1, M2$ e $M3$, mostrado na Fig. 3(b) são considerados passivos. Assim, as únicas articulações ativas que fornecem movimento ao manipulador são as juntas ativas em $M4, M5$ e $M6$. Essas juntas são movidas por motores planos Maxon $EC60$ sem escova, com $100W$ de potência e uma corrente de $2,3A$, acoplados a redutores planetários $GP52C$ com uma redução de $3,5 : 1$, proporcionando uma rotação nominal de $1200RPM$ e torque nominal de $0,82Nm$. Cada um dos motores possui um controlador Maxon $EPOS250/5$ com alimentação de até $50Vdc$ e corrente de $5A$.

Um diagrama da comunicação pode ser visto na Fig. 3(b). A comunicação destes motores com o $DSPACE1103$ é feita via protocolo CAN com uma taxa de transmissão de $250kbit/s$. Portanto, tanto o acionamento do motor quanto a aquisição dos dados dos *encoders* são realizados dessa forma. Medidores de tensão HBM 350 – E arranjados com ponte completa foram anexados a cada link do manipulador para realizar as medições de deformação de cada elo, quando o manipulador executa uma tarefa. As informações do extensômetro precisam ser lidas pelas entradas A/D da DSPACE e, por esse motivo, passam por um amplificador de sinal HBM HB40 CLIPX.

Para medir diretamente a posição do atuador final do manipulador, é usada uma câmera *oCam - 5CRO - U* com interface USB 3.0 com sensor de imagem CMOS e obturador de rolamento, com resolução de 640×480 pixels e uma taxa de quadros máxima de $120fps$. As imagens obtidas pela câmera são processadas em um computador por meio de um filtro que detectará os pontos mais relevantes do manipulador: o centro do efetuador, D_i , e os pontos fixos A_i (ver Fig. 3(a)). Este filtro é implementado no Visual Studio e utiliza uma biblioteca de visão computacional denominada OpenCV, desenvolvida em C++. A transmissão dos dados medidos por cada quadro capturado pela câmera é feita por meio de comunicação serial através do padrão $RS - 232$ entre o computador e a placa de aquisição DSPACE, com frequência de $60fps$.

Com dados de medição direta da câmera, deformações do medidor de tensão e posição angular dos *encoders*, a DSPACE envia esse conjunto de dados para um computador central onde é possível capturar todas essas informações simultaneamente. É necessário tratar os dados dos extensômetros e da câmera com um filtro digital passa-baixa, pois os sinais obtidos pelos extensômetros possuem ruídos de alta frequência.

2. MATERIAIS E MÉTODOS

2.2.2 Manipuladores Cinemáticos de Cadeia Paralela

O manipulador de cadeia paralela 3RRR é um mecanismo planar que tem três cadeias cinemáticas conectadas ao efetuator $A_i B_i$, onde o subscrito $i = 1, 2, 3$ está de acordo com a cadeia cinemática. Conforme mostrado na Fig. 3(a), as três articulações ativas do manipulador transmitem o movimento para o efetuator, com centro no ponto D . O sistema de coordenadas global fixado no efetuator O_{xyo} está localizado no ponto D e tem uma orientação, em relação a este sistema de coordenadas, de ângulo α . A orientação angular dos elos $A_i B_i$ é dada pelo ângulo θ_i , e β_i é a orientação angular para os elos $B_i C_i$. O vetor posição do efetuator $\mathbf{X} = [x \ y \ \alpha]^T$, é relativo ao sistema de coordenadas fixas e é o conjunto de pontos que serão estimados, dada uma trajetória que o manipulador irá executar.

De acordo com a Fig. 3(a), o manipulador com elos rígidos pode ser modelado cinematicamente considerando a restrição geométrica dos elos $\|B_i C_i\| = \|\mathbf{r}_{C_i} - \mathbf{r}_{B_i}\| = l_2$, nos permite derivar uma equação para cada ângulo θ_i (Fontes and da Silva, 2016), onde $e_{i1} = -2l_1\rho_i$, $e_{i2} = -2l_1\mu_i$, $e_{i3} = \mu_i^2 + \rho_i^2 + l_1^2 - l_2^2$, $\mu_i = x_D + h_i \cos(\lambda_i + \alpha) - a_i \cos(\lambda_i)$ e $\rho_i = y_D + h_i \sin(\lambda_i + \alpha) - a_i \sin(\lambda_i)$. A Eq. 2 também é chamado de cinemática inversa para o manipulador 3RRR.

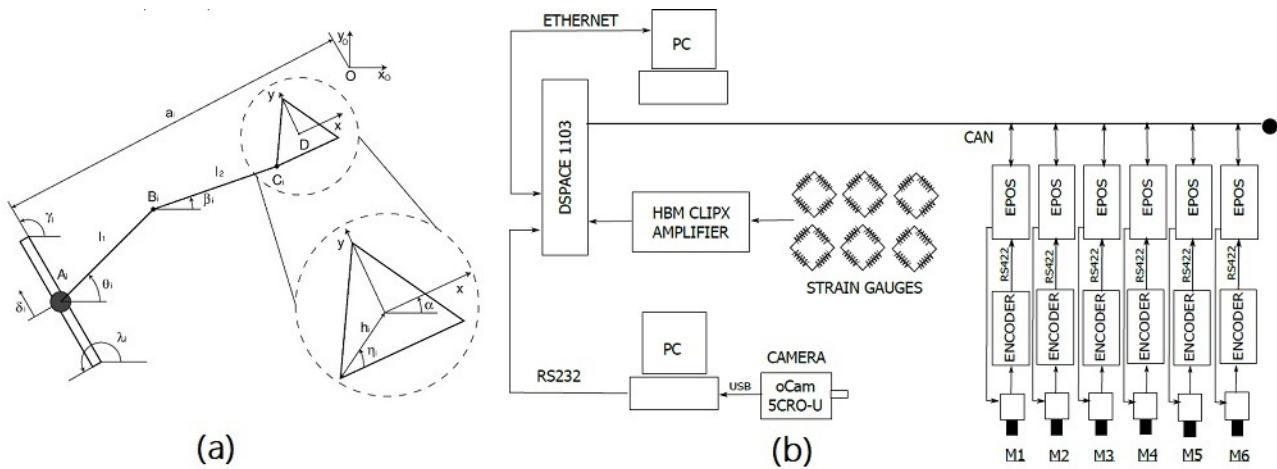


Figura 3. (a) Ilustração de uma cadeia cinemática do manipulador 3RRR, (b) Diagrama da instrumentação e comunicação experimental do protótipo.

$$\theta_i = 2 \tan^{-1} \left(\frac{-e_{i1} \pm \sqrt{e_{i1}^2 + e_{i2}^2 - e_{i3}^2}}{e_{i3} - e_{i2}} \right). \quad (2)$$

Para determinar a velocidade da articulação ativa, $\dot{\Theta} = [\dot{\theta}_1 \ \dot{\theta}_2 \ \dot{\theta}_3]^T$, e a velocidade do efetuator $\dot{\mathbf{X}} = [\dot{x} \ \dot{y} \ \dot{\alpha}]^T$, utiliza-se a equação de restrição geométrica e a derivamos em relação ao tempo e também assumindo que λ_i é constante, é possível chegar à seguinte equação após algumas manipulações matemáticas

$$l_2 \cos(\beta_i) \dot{x}_P + l_2 \sin(\beta_i) \dot{y}_P + l_2 h \dot{\alpha} \sin(\beta_i - \alpha - \lambda_i) = l_1 l_2 \dot{\theta} \sin(\beta_i - \theta_i). \quad (3)$$

Assim, é possível reescrever a Eq. 3 na forma matricial para determinar a relação que mapeia as velocidades no espaço das juntas $\dot{\Theta}$, com as velocidades no espaço da tarefa $\dot{\mathbf{X}}$ como sendo $\mathbf{A}\dot{\mathbf{X}} = \mathbf{B}\dot{\Theta}$, onde

$$\mathbf{A} = \begin{bmatrix} l_2 \cos(\beta_1) & l_2 \sin(\beta_1) & l_2 h \sin(\beta_1 - \alpha - \lambda_1) \\ l_2 \cos(\beta_2) & l_2 \sin(\beta_2) & l_2 h \sin(\beta_2 - \alpha - \lambda_2) \\ l_2 \cos(\beta_3) & l_2 \sin(\beta_3) & l_2 h \sin(\beta_3 - \alpha - \lambda_3) \end{bmatrix} \quad (4)$$

$$\mathbf{B} = \begin{bmatrix} l_1 l_2 \sin(\beta_1 - \theta_1) & 0 & 0 \\ 0 & l_1 l_2 \sin(\beta_2 - \theta_2) & 0 \\ 0 & 0 & l_1 l_2 \sin(\beta_3 - \theta_3) \end{bmatrix} \quad (5)$$

Portanto, a matriz Jacobiana que mapeia as velocidades no espaço das juntas para o espaço da tarefa é tal que $\mathbf{J} = \mathbf{A}^{-1}\mathbf{B}$ se \mathbf{A} for invertível. O desenvolvimento do modelo cinemático inverso se faz necessário para obter-se o valor

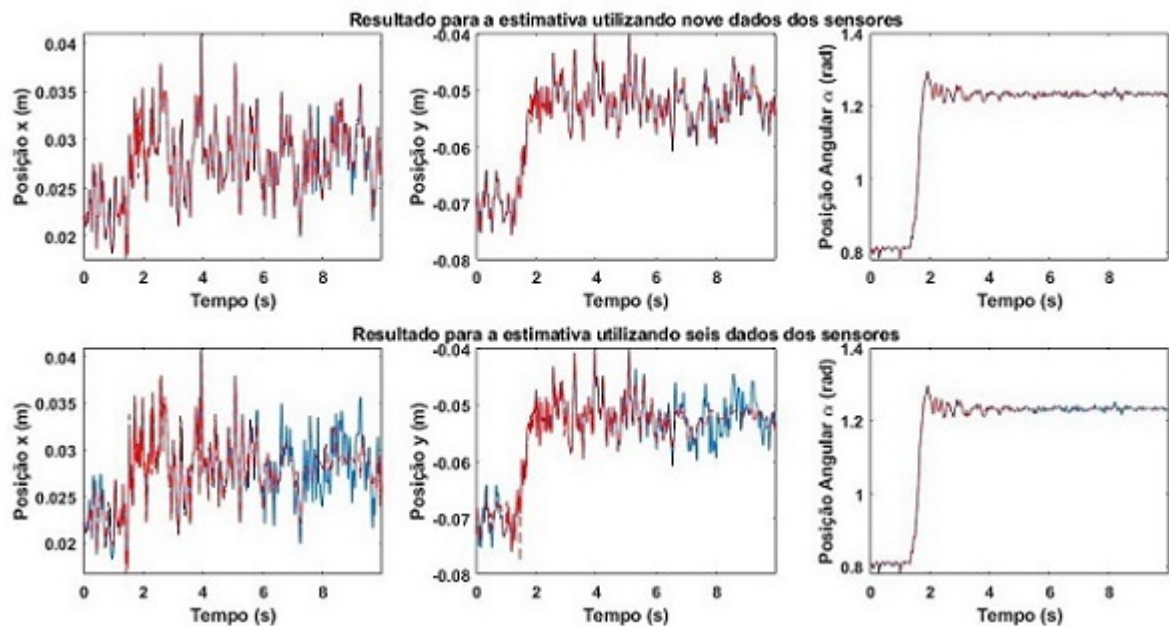


Figura 4. Gráficos comparativos entre os resultados das estimativas.

correto dos ângulos das juntas ativas do manipulador. Esses dados de posição angulares provenientes dos *encoders* precisam ser inseridos no modelo desenvolvido nesta seção para que possua a devida unidade e esteja no referencial correto.

3. RESULTADOS

Como descrito nas seções anteriores, um algoritmo de RNA utilizando a arquitetura de *Perceptron* Multicamadas foi desenvolvida para estimar a pose do efetuador do manipulador. Utilizando os dados da câmera, foi possível mapear a trajetória das coordenadas lineares x , y e a trajetória angular α que o manipulador desenvolve após realizar a movimentação proposta. Foi feita uma avaliação do número de neurônios que a RNA irá utilizar, de forma a minimizar entre a curva objetivo, capturada pela câmera, e a curva estimada pelo algoritmo. Essa minimização é baseada no desempenho que a rede irá executar e isso será mensurado de acordo com o Erro Quadrático Médio. Quanto menor for o valor do erro, melhor é o desempenho da rede, e mais fiel o metamodelo construído está da forma como o sistema realmente se comporta. O número de neurônios na camada escondida pode ir de um até 150, variando a cada cinco. Em cada processo de treinamento, a mesma arquitetura com o determinado número de neurônios é avaliado cinco vezes de forma a evitar que o processo de treinamento, coincidentemente, escolha uma arquitetura que esteja em um mínimo local.

Os resultado do treinamento para o melhor número de neurônios no primeiro caso, utilizando seis medidas de extensômetros e três de *encoders* pode ser visto pelos três gráficos da primeira linha da Fig. 4. As curvas sólidas em azul representam a curva obtida pela medição direta da câmera enquanto o efetuador se movimentava enquanto a linha em vermelho representa a estimativa feita pela RNA construída. Da esquerda para a direita está o gráfico da coordenada no eixo x , em seguida a coordenada no eixo y e por fim a posição angular α do centro do efetuador do manipulador. Esse resultado, como comentado anteriormente, foi obtido avaliando o desempenho da rede durante o processo de treinamento. Para a estimativa da posição x a rede obteve um desempenho de 1.5727×10^{-7} , baseado no Erro Quadrático Médio, utilizando 141 neurônios em sua camada escondida. No segundo gráfico, estimativa da posição y , a rede desempenhou um resultado de 1.2362×10^{-7} , totalizando 136 neurônios. Por fim, para a estimativa da posição angular α do manipulador, a mesma obteve um desempenho de 1.5283×10^{-7} com um número de neurônios de 126.

Para o segundo caso, onde foram utilizado apenas três dados dos extensômetros e três dados de *encoders* o resultado final da estimativa, curva pontilhada em vermelho, pode ser visto pelos gráficos na segunda linha da Fig. 4. O primeiro gráfico, que diz respeito a estimativa da posição no eixo x , obteve um desempenho de 3.0315×10^{-6} com um número total de 116 neurônios em sua camada escondida. No segundo gráfico, estimativa da posição do efetuador no eixo y , a rede obteve um desempenho de 3.6014×10^{-6} utilizando 121 neurônios em sua camada escondida. Finalmente, para estimar a posição angular α do manipulador, o resultado do treinamento da rede gerou um desempenho de 1.2649×10^{-5} com um número de 136 neurônios em sua camada escondida.



7. RESPONSABILIDADE PELAS INFORMAÇÕES

4. CONCLUSÕES E DISCUSSÕES

O projeto de manipuladores de cadeia cinemática paralela com elos flexíveis se mostra uma tarefa de alta complexidade, exigindo muita atenção durante seu desenvolvimento e podendo produzir resultados insatisfatórios. A redução de inércia dos componentes móveis do manipulador proposta por diversos pesquisadores, se mostrou uma das etapas cruciais para o entendimento da complexidade deste problema. A flexibilidade na estrutura do manipulador faz com que a medição precisa da posição do efetuador se torne uma tarefa ainda mais complicada de se obter.

Para contornar essa situação, a proposta de construção de um metamodelo baseado em uma Rede Neural Artificial para estimar essa posição, se mostrou válida e apresentou resultados satisfatórios. A implementação de diferentes subconjuntos heterogêneos para as fases de treinamento e teste, se mostraram de importante relevância para se obter uma validação cruzada entre os dados dos experimentos. Além disso ficou evidente que o número de dados utilizados na camada de entrada da rede possui uma forte influência no desempenho final do algoritmo de RNA. Observou-se com os resultados apresentados na seção anterior, que utilizar apenas três dados do extensômetro, ao invés de usar os seis disponíveis, ocasionou em um aumento do valor do erro, piorando dessa forma o desempenho da rede.

Portanto, este trabalho se mostrou relevante para problemas de estimativa da postura de manipuladores de cadeia cinemática paralela, visto a dificuldade de adquirir de maneira satisfatória a postura desse tipo de manipulador. Os resultados obtidos são satisfatórios para os objetivos e problemas propostos, tendo em vista o desempenho da rede construída para realizar essa estimativa. Para um futuro trabalho, pode-se utilizar os resultados obtidos pelas estimativas obtidas aqui, para realizar um projeto de controle do manipulador, expandindo ainda mais o projeto para outros campos dentro da Dinâmica e Mecatrônica.

5. REFERÊNCIAS

- Bellakehal, S., Andreff, N., Mezouar, Y. and Tadjine, M., 2011. “Vision/force control of parallel robots”. *Mechanism and Machine Theory*, Vol. 46, No. 10, pp. 1376–1395. doi:10.1016/j.mechmachtheory.2011.05.010. URL <https://doi.org/10.1016/j.mechmachtheory.2011.05.010>.
- Colombo, F.T., de Carvalho Fontes, J.V. and da Silva, M.M., 2019. “A visual servoing strategy under limited frame rates for planar parallel kinematic machines”. *Journal of Intelligent & Robotic Systems*, Vol. 96, No. 1, pp. 95–107. doi:10.1007/s10846-019-00982-7. URL <https://doi.org/10.1007/s10846-019-00982-7>.
- da Silva, I.N., Spatti, D.H., Flauzino, R.A., Liboni, L.H.B. and dos Reis Alves, S.F., 2017. *Artificial Neural Networks*. Springer International Publishing. doi:10.1007/978-3-319-43162-8. URL <https://doi.org/10.1007/978-3-319-43162-8>.
- de Carvalho Fontes, J.V., Colombo, F.T. and da Silva, M.M., 2021. “Model-based joint and task space control strategies for a kinematically redundant parallel manipulator”. *Robotica*, Vol. x, No. x. doi:10.1007/xxx. URL <https://doi.org/xxx>.
- de Carvalho Fontes, J.V., Santos, J.C. and da Silva, M.M., 2018. “Numerical and experimental evaluation of the dynamic performance of kinematically redundant parallel manipulators”. *Journal of the Brazilian Society of Mechanical Sciences and Engineering*, Vol. 40, No. 3. doi:10.1007/s40430-018-1072-1. URL <https://doi.org/10.1007/s40430-018-1072-1>.
- Fontes, J.V. and da Silva, M.M., 2016. “On the dynamic performance of parallel kinematic manipulators with actuation and kinematic redundancies”. *Mechanism and Machine Theory*, Vol. 103, pp. 148–166. doi:10.1016/j.mechmachtheory.2016.05.004. URL <https://doi.org/10.1016/j.mechmachtheory.2016.05.004>.
- Haykin, S., 2009. *Neural Networks and Learning Machines*, Vol. third. Person Education, Upper Saddle River, NJ.
- Merlet, J.P., 2006. *Parallel Robots*. Springer Netherlands.
- Mohan, S., Mohanta, J.K., Huesing, M. and Corves, B., 2017. “Dual-loop motion control for geometric errors and joint clearances compensation of a planar 2-PRP1-PPR manipulator”. In *Mechanisms, Transmissions and Applications*, Springer International Publishing, pp. 171–180. doi:10.1007/978-3-319-60702-3_18. URL

6. AGRADECIMENTOS

Este trabalho foi financiado pela FAPESP 2018/21336-0. Fábio, Guilherme e Maíra são gratos pelas bolsas de estudos da CAPES e CNPq 301338/2018-3, respectivamente.

7. RESPONSABILIDADE PELAS INFORMAÇÕES

Os autores são os únicos responsáveis pelas informações incluídas neste trabalho.