

IDENTIFICAÇÃO DA DINÂMICA DE UM MANIPULADOR ROBÓTICO FLEXÍVEL 3RRR UTILIZANDO REDE NEURAL

Tony Jun Tanaka, tonyjt@usp.br¹
Renan Sanches Geronel, renansanches@usp.br¹
Maíra Martins da Silva, mairams@sc.usp.br¹

¹Universidade de São Paulo (USP), Departamento de Engenharia Mecânica, Escola de Engenharia de São Carlos, Av. Trab. São Carlense, 400 - Parque Arnold Schmidt, São Carlos/São Paulo, Brazil

Resumo. A crescente melhora nos processos produtivos têm levado a constantes avanços tecnológicos no campo industrial com relação a diferentes tipos de manipuladores. Basicamente, os manipuladores são divididos entre serial e paralelo, onde os seriais possuem cadeia aberta, enquanto os paralelos se conectam a um efetor final mútuo. Os manipuladores paralelos apresentam uma maior demanda, quando é necessária uma maior precisão e velocidade. Os manipuladores com elos flexíveis apresentam vantagens adicionais com relação aos com elos rígidos, como menor peso e menor potência requerida. Entretanto, a dificuldade de obtenção de um modelo apropriado, torna essa tarefa desafiadora. Redes Neurais aparecem como uma alternativa interessante para o reconhecimento de padrões dinâmicos complexos. Neste trabalho, um manipulador paralelo do tipo 3RRR é utilizado a fim de coletar diferentes dados para o treinamento, teste e validação da rede neural proposta. Seis entradas são utilizadas (três referentes às posições angulares dos motores e três referentes aos sinais dos extensômetros), a fim de estimar a posição final, incluindo a posição linear e angular. Os resultados mostram que a utilização da Rede Neural é uma alternativa promissora para a estimativa de modelos dinâmicos.

Palavras chave: Manipulador Paralelo. Modelo Dinâmico. Rede Neural

Abstract. The continuous improvement in production processes has led to constant technological advancements in the industrial field concerning different types of manipulators. Manipulators are often divided into serial and parallel types, where serial ones have an open chain, while parallel ones are connected to a common end-effector. Parallel manipulators are in higher demand when greater precision and speed are required. Those with flexible links offer additional advantages over rigid-link manipulators, such as lower weight and reduced power requirements. However, obtaining an appropriate model is challenging. Neural Networks emerge as an interesting alternative for recognizing complex dynamic patterns. In this work, a 3RRR-type parallel manipulator is used to collect various data for the training, testing, and validation of the proposed neural network. Six inputs are used (three related to the angular positions of the motors and three related to the strain gauge signals) to estimate the final position, including both linear and angular positions. The results show that using Neural Networks is a promising alternative for estimating dynamic models.

Keywords: Parallel Manipulator. Dynamic Model. Neural Network.

1. INTRODUÇÃO

A busca pela redução dos custos nos processos produtivos leva constantes avanços tecnológicos no campo industrial em diferentes tipos de manipuladores, projetados para garantir maior precisão, velocidade, qualidade do produto e redução no tempo de produção. Ao longo dos anos, os manipuladores paralelos têm sido empregados visando garantir uma precisão e integração positiva no processo. No entanto, manipuladores em série, frequentemente apresentam elevado peso, o que resulta na diminuição significativa na mobilidade desses braços robóticos devido às limitações de torque de saída dos atuadores (Dwivedy e Eberhard, 2006). Manipuladores paralelos, por outro lado, apresentam maior eficiência energética e demandam menor inércia para o seu movimento, visto que são mais leves do que os em série. No entanto, controlar os manipuladores paralelos representa uma tarefa desafiadora devido à complexidade em sua dinâmica e incertezas (Paccot et al., 2009).

Manipuladores paralelos, tanto os com elos rígidos como flexíveis, possuem eficiência de energia e capacidades dinâmicas maiores em relação a manipuladores em série. No entanto, o controle desses sistemas é complexo devido a apresentarem uma dinâmica acoplada e a ausência direta de medição da posição e orientação do efector final. No caso dos manipuladores paralelos com elos rígidos, vê-se a utilização do controle baseado em modelo, visto que apresentam um equacionamento já conhecido na literatura, o que torna uma tarefa menos complexa em desenvolver controles modernos, que lidam com incertezas e não linearidades (Bennehar et al., 2017; Saied et al., 2018). Além disso, técnicas baseadas em visão e processamento de imagem estão sendo usadas para resolver essas incertezas. Por outro lado, manipuladores paralelos com elos flexíveis apresentam desafios adicionais com relação a dinâmica, acoplamento, incertezas e deformação dos elos. Apesar das vantagens desses manipuladores com relação aos com elos rígidos, como menor peso, menor potência requerida, a dificuldade de obtenção de um modelo apropriado, torna essa tarefa desafiadora (Geronel et al., 2024).

Nesse sentido, estratégias sem modelo surgem como alternativas promissoras para lidar com sistemas altamente complexos, como os sistemas de elos flexíveis. Chen et al. (2019) avalia uma metodologia de controle de dois níveis para melhorar a precisão da trajetória do treinamento de reabilitação, garantindo a segurança do paciente. Além do rastreamento da trajetória, uma estratégia de controle de visão/deformação de circuito duplo é implementada para mitigar as características de vibração. Além disso, um protótipo 3RRR com flexibilidade é usado para investigar uma estratégia de controle híbrido (da Silva et al., 2024). O controle híbrido é composto por dois laços: o controle visual baseado na posição e o controle de feedback baseado na deformação. Enquanto a posição usa uma câmera para calcular a posição do efector final, o feedback, baseado na deformação, usa extensômetros para avaliar a deformação do elo. Apesar de compensar positivamente a deformação dos elos, a estratégia sem modelo frequentemente demanda equipamentos adicionais e o desenvolvimento de controladores mais complexos. Assim, o emprego de Redes Neurais Artificiais (RN) para dinâmica direta pode ser útil não apenas como projeto de modelo, mas também para aprimorar modelos com dados experimentais.

O aprendizado de máquina informado por física é um novo método que utiliza dados em conjunto com conhecimentos prévios para formar modelos. Essa abordagem, diferentemente de redes neurais profundas, não necessita de um grande banco de dados para funcionar, pois utilizar conhecimentos prévios, como leis físicas e observações, cria restrições teóricas, vieses indutivas e observacionais. Esses fatores aumentam o desempenho do algoritmo de aprendizado, requerendo menos dados para gerar modelos menores e eficientes para controle (Karniadakis et al., 2021). Outra vantagem desse método é a sua capacidade de integrar perfeitamente dados e operadores matemáticos abstratos, incluindo equações diferenciais parciais com informações físicas completas ou incompletas (Willard et al., 2022).

Este trabalho visa analisar a viabilidade de modelar um sistema flexível complexo por meio do aprendizado de máquina. Inicialmente, adota-se uma estratégia de controle para a geração dos dados de treinamento da rede neural. Em seguida, a rede treinada será validada com o intuito de avaliar sua eficácia na construção de modelos capazes de representar adequadamente manipuladores paralelos com elos flexíveis. O restante do trabalho é organizado da seguinte forma: A Seção 2 apresenta a arquitetura do manipulador paralelo e o esquema de comunicação. Somado a isso, é brevemente discutido como o controle proposto será utilizado para a coleta de dados. Uma Rede Neural Artificial é empregada para o teste e validação dos dados coletados. Enquanto a Seção 3 explora os principais resultados e discussão alcançados, a seção 4 apresenta as principais conclusões do trabalho.

2. METODOLOGIA

Esta seção descreve o protótipo utilizado e os principais equipamentos necessários para a sua comunicação. Inicialmente, é importante mencionar que o manipulador é originalmente do tipo 3PRRR, no qual a letra P simboliza uma junta prismática, enquanto R denota uma junta de revolução. As letras sublinhadas são referentes às juntas ativas, enquanto as não sublinhadas estão relacionadas às juntas passivas. Neste trabalho, as juntas passivas são bloqueadas, ou seja, não há movimento translacional dos motores, fazendo com o que o sistema mecânico seja simplificado para um manipulador paralelo 3RRR. O número 3 indica que o manipulador possui 3 cadeias e os termos R, indicam que em cada cadeia, há a presença de três juntas de revolução, sendo apenas a primeira ativa (neste caso, definida pelo motor). Todas as cadeias possuem um destino mútuo, que é designado pelo efector final (como visto na figura pelo triângulo). A Fig. 1 mostra uma foto do manipulador paralelo utilizado.




Figura 1. Foto do manipulador paralelo 3RRR com elos flexíveis

2.1. Instrumentação

Esta subseção apresenta a instrumentação e os equipamentos utilizados para a comunicação. A Fig. 2 mostra a instrumentação utilizada para a construção do experimento. Vê-se que a placa dSPACE 1103 é empregada visando estabelecer a conexão entre esses equipamentos. Somado a isso, três juntas rotativas ativas, representadas pelos motores (Motor 1, Motor 2 e Motor 3), são empregadas para gerar movimento ao sistema. Motores do tipo Maxon EC60 planos sem escovas, com 100W de potência de entrega e uma corrente nominal de 2.3 A são então utilizados em cada cadeia do sistema. A comunicação entre os controladores EPOS e o dSPACE 1103 é conduzida via protocolo CAN a uma taxa de transmissão de 250 kbit/s, e a Ethernet é usada para estabelecer a comunicação entre a placa e o computador. Visto que o trabalho adota um sistema de controle se modelo para a obtenção dos dados experimentais, um sensor é necessário para o cálculo da posição do efector. Uma câmera oCam-5CRO-U é utilizada para coletar imagens em tempo real do manipulador paralelo. A oCam-5CRO-U requer uma interface USB 3.0 e apresenta uma resolução de 640x480 pixels, com uma taxa de quadros máxima de 60 fps (do inglês *frames per second*).




Figura 2. Instrumentação empregada para o experimento

A câmera é fixada acima do protótipo a fim de obter imagens de todo o espaço de trabalho. Como mencionado, as imagens, que são capturadas pela câmera, são processadas pelo Computador 1 para determinar a posição do efector final. Note que, o manipulador paralelo é considerado plano, uma vez que o movimento é restrito ao longo das direções x e y , enquanto $z = 0$. Após as imagens serem capturadas pela câmera, o Algoritmo de Processamento de Imagens (veja em Geronel et al. (2024)) é usado para estimar a posição linear (x, y) e angular (α) do efector final, indicados na Fig. 3.

Neste caso, a posição do efector é definido pelo vetor correspondente $X = [x, y, \alpha]^T$.




Figura 3. Características geométricas do 3RRR

Neste caso, os elos utilizados para construir o protótipo são feitos de aço mola AISI 6150. Cada elo apresenta um comprimento de 318,5 mm, largura de 3,5 mm e espessura de 0,7 mm. Devido ao baixo peso dos elos, essa flexibilidade pode gerar a vibração indesejada no sistema, gerada principalmente pela deformação dos elos. Assim, extensômetros HBM 350-E, são fixados em cada elo, visando coletar em tempo real, a deformação de cada elo flexível. O sinal coletado é enviado para amplificadores de sinal HBM HB40 CLIPX, e então enviados a dSPACE 1103. O Computador 2 é usado para projetar a estratégia de controle adotada, realizada em Matlab/SIMULINK. Portanto, torna-se importante observar que todo o sinal medido é coletado através da câmera e dos extensômetros, codificados e levados para a dSPACE e SIMULINK, a fim de gerar um sinal de controle apropriado para realizar o movimento do protótipo 3RRR.

2.1 Coleta dos dados

Para a coleta dos dados, foi utilizado a estratégia com modelo, através da utilização de um controlador de modos deslizantes. Através dessa estratégia, é possível combinar as imagens (e consequentemente o cálculo do efector final) e a deformação (coletada pelos extensômetros), a fim de estabelecer a posição angular e linear do efector, já lidando com os efeitos de deformação. Assim o modelo de controle desenvolvido é dividido em dois laços: enquanto o laço da câmera estima a posição do efector final, o laço de deformação é responsável por compensar a flexibilidade do protótipo. A câmera, fixada acima do protótipo, é utilizada para coletar as imagens em tempo real, e através da utilização do Algoritmo de Processamento de Imagens, a posição do efector final é estimada. Neste caso, o controlador de modos deslizantes é empregado devido a sua robustez e simplicidade. Baseado no erro entre os estados desejado e real (calculados em cada iteração), a lei de controle correspondente, da câmera, pode ser calculada. Em seguida, baseada no erro entre as deformações obtidas pelos extensômetros e o valor do sinal desejado (0, ausência de vibração), uma lei de controle é estabelecida. Neste trabalho, assumimos alguns filtros, incluindo o Bandstop de segunda ordem (Notch), os filtros passa-alta e passa-baixa de segunda ordem, visando remover o ruído do sinal.

Assim, diferentes trajetórias, definidas como entrada degrau, são utilizadas para a coleta dos dados. O experimento é executado diversas vezes, a fim de estabelecer um banco de dados seguro. Com isso, o banco de dados será dividido entre treinamento, teste e validação. Os dados treinados e testados não serão os mesmos utilizados para a validação. Observe que, neste primeiro caso, precisamos de três "sensores" diferentes para adquirir os sinais: uma câmera, codificadores e extensômetros. Isso aumenta a complexidade do protótipo, emprega diferentes premissas de MPs com enlacs rígidos e exige um tempo de processamento de custo superior. Portanto, como forma de retirar a necessidade de sensores adicionais, uma Rede Neural artificial é projetada visando reconhecer padrões complexos de sistemas mecânicos.

2.2 Rede Neural

A Rede Neural utilizada é do tipo *feedforward* com múltiplas camadas ocultas, projetada para mapear relações não lineares entre variáveis de entrada e estados dinâmicos do sistema. A arquitetura proposta é composta por três estágios: entrada, camadas ocultas e saída. As entradas correspondem às posições angulares dos motores ($\theta_1, \theta_2, \theta_3$) e aos sinais dos extensômetros (s_1, s_2, s_3), enquanto a saída representa a posição da extremidade do efector (x, y, α). Com relação às camadas ocultas, há neurônios que irão processar informações e aprender uma tarefa específica. A rede neural recebe uma entrada u e a propaga pelas camadas ocultas l , aplicando os pesos W e bias b , conforme a Eq. 1.

$$u^{l+1} = W^l u^l + b^l, \text{ para } l = 1, \dots, L - 1 \quad (1)$$

Em seguida, um operador de soma realiza a soma dos sinais ponderados de cada sinapse l do neurônio. A função de ativação é então aplicada a cada camada oculta para limitar a saída do neurônio a um determinado intervalo e melhorar as respostas não lineares do algoritmo (Garpeilli et al., 2023). A função ReLU (*Rectified Linear Unit*) é definida por $ReLU(u) = \max(0, u)$, que retorna u se $u > 0$, caso contrário, retorna zero. O procedimento utilizado na etapa de aprendizado minimiza a função objetivo para modificar os valores dos pesos e bias a fim de alcançar a minimização desejada. Para realizar esse processo, uma função de perda deve ser definida para comparar a saída da rede com o valor esperado. No nosso caso, o erro é estimado pela técnica do Erro Quadrático Médio (MSE), conforme a Eq. 2.

$$L = \frac{1}{N} \sum_{i=1}^N (y_i + \hat{y}_i)^2 \quad (2)$$

As variáveis y_i e $\hat{y}_i$ representam os valores reais e estimados pela rede neural, respectivamente, e N é o comprimento dos vetores. O processo de aprendizado é implementado usando o método do gradiente. A função de perda (Eq. 2) é usada para propagar os erros da camada de saída até a primeira camada de cada neurônio, as derivadas parciais $\partial(MSE) = \partial W$ e $\partial(MSE) = \partial b$ são calculadas com relação aos pesos e bias correspondentes. Com base nas derivadas, calcula-se o gradiente da função de perda, e o uso do método da descida do gradiente permite a atualização dos valores de pesos e bias para realizar o aprendizado da rede neural. Para a implementação, os dados foram divididos em dois conjuntos: o primeiro relativo aos dados para treino e teste, enquanto o segundo para validação. O primeiro grupo foi ainda dividido em 90% dos dados para treino e 10% para teste. A Fig. 4 ilustra a rede neural adotada para o trabalho.




Figura 4. Estrutura da rede neural

2.3 Conjunto de Dados

A Fig. 5 a seguir ilustra duas amostras dos dados utilizados como entrada da rede neural, as posições angulares dos motores e deformações nos elos. Também são mostradas a posição e orientação do efector final, os dados de saída esperados.




Figura 5. Duas amostras entre os conjuntos de dados utilizados no treinamento e teste da rede neural

3. RESULTADOS E DISCUSSÃO

A Fig. 6 apresenta a comparação entre os dados reais obtidos experimentalmente e os valores estimados pela Rede Neural para as variáveis x , y e α do efector final. Observa-se que a rede neural proposta foi capaz de capturar de maneira satisfatória a dinâmica não linear do manipulador paralelo 3RRR com elos flexíveis.




Figura 6. Comparação entre as posições reais e estimadas pela rede neural

Para a componente x , nota-se que a estimativa da rede neural (curva vermelha) segue de forma bem próxima os dados reais (curva preta), com discrepâncias localizadas principalmente na fase de transição e amortecimento. Esse comportamento é esperado devido à natureza complexa das oscilações induzidas pela flexibilidade dos elos.

No caso da coordenada y , a rede neural também se mostra eficaz, mesmo diante de oscilações mais acentuadas. A correspondência entre os sinais evidencia que a rede conseguiu aprender o padrão vibratório gerado pelas deformações dos elos, capturando tanto os efeitos transientes quanto a convergência ao regime estacionário.

A variável angular α apresenta maior discrepância na fase de resposta inicial, com amortecimentos menos precisos. Essa limitação é atribuída à maior sensibilidade da orientação às deformações dos elos e ao ruído dos sensores. Apesar disso, a rede ainda consegue capturar a tendência geral da resposta.

Com base nesses dados e na estrutura adotada, observa-se que a arquitetura *feedforward* com múltiplas camadas ocultas foi eficiente na tarefa de mapeamento não linear, sendo capaz de estimar a posição final do efector com boa precisão. A técnica de minimização baseada em MSE e o uso de funções de ativação ReLU permitiram um aprendizado estável, mesmo em um sistema com acoplamento dinâmico e flexibilidade estrutural.

4. CONCLUSÃO

Este trabalho explorou a aplicação de uma Rede Neural Artificial para a modelagem direta da dinâmica de um manipulador paralelo 3RRR com elos flexíveis. Utilizando dados experimentais obtidos de um protótipo físico, a rede foi treinada com seis variáveis de entrada (três posições angulares dos motores e três sinais dos extensômetros) para estimar a posição linear e angular do efector. Os resultados mostram que a rede neural apresenta bom desempenho na predição das variáveis x e y , e desempenho positivo para a variável angular α , mesmo diante das complexidades causadas pela flexibilidade dos elos. A boa correlação entre os dados reais e os valores estimados reforça a viabilidade da utilização de redes neurais como ferramenta para a modelagem de sistemas robóticos flexíveis.

Conclui-se que a abordagem baseada em redes neurais pode reduzir a dependência de sensores adicionais e simplificar o controle de manipuladores paralelos flexíveis. Como trabalho futuro, sugere-se a exploração de redes recorrentes, redes convolucionais ou redes informadas por física (PINNs) com o objetivo de melhorar a robustez e precisão do modelo.

5. AGRADECIMENTOS

Os autores gostariam de agradecer a Fundação de Amparo à Pesquisa do Estado de São Paulo — FAPESP [processos números 18/21336-0, 23/07834-6, 24/07967-9] e o Conselho Nacional de Desenvolvimento Científico e Tecnológico — CNPq [processo número 303884/2021-5] pelo apoio financeiro.

6. REFERÊNCIAS

Bennehar, M., Chemori, A., Bouri, M., Jenni, L. e Pierrot, F., 2017. A new RISE-based adaptive control of PKMs: design, stability analysis and experiments. *Internat. J. Control*, 91(3), 593–607. <http://dx.doi.org/10.1080/00207179.2017.1286536>

- Chen, Q., Zi, B., Sun, Z., Li, Y. e Xu, Q., 2019. Design and development of a new cable-driven parallel robot for waist rehabilitation. *IEEE/ASME Transactions on Mechatronics*, 24(4), 1497–1507. <https://ieeexplore.ieee.org/abstract/document/8716563>
- da Silva, M.M., Colombo, F.T., de Oliveira, G.C. e de Oliveira, L.P.R., 2024. Hybrid vision/strain-based control strategy for a parallel manipulator with flexible links. *Mechanism and Machine Theory*, 191, 105508. <https://doi.org/10.1016/j.mechmachtheory.2023.105508>
- Dwivedy, S.K. e Eberhard, P., 2006. Dynamic analysis of flexible manipulators, a literature review. *Mechanism and Machine Theory*, 41(7), 749–777. <https://doi.org/10.1016/j.mechmachtheory.2006.01.014>
- Garpelli, L.N., Alves, D.S., Cavalca, K.L. e de Castro, H.F., 2023. Physics-guided neural networks applied in rotor unbalance problems. *Structural Health Monitoring*, 22(6), 4117–4130. <https://doi.org/10.1177/14759217231163081>
- Geronel, R.S., de Oliveira, G.C. e da Silva, M.M., 2024. Dual-loop control strategies for vibration attenuation of a flexible parallel manipulator. *Journal of Vibration and Control*, 1–13. <https://journals.sagepub.com/doi/10.1177/10775463241307702>
- Karniadakis, G.E., Kevrekidis, I.G., Lu, L., Perdikaris, P., Wang, S. e Yang, L., 2021. Physics-informed machine learning. *Nature Reviews Physics*, 3, 422–440. <https://doi.org/10.1038/s42254-021-00314-5>
- Paccot, F., Andreff, N. e Martinet, P., 2009. A review on the dynamic control of parallel kinematic machines: theory and experiments. *The International Journal of Robotics Research*, 28(3), 395–416. <https://doi.org/10.1177/0278364908096>
- Saied, H., Chemori, A., Rafei, M.E., Francis, C. e Pierrot, F., 2018. From non-model-based to model-based control of PKMs: A comparative study. In: *Mechanism, Machine, Robotics and Mechatronics Sciences*, Springer International Publishing, pp. 153–169. <http://dx.doi.org/10.1007/978-3-319-89911-4-12>
- Willard, J., Jia, X., Xu, S., Steinbach, M. e Kumar, V., 2022. Integrating physics-based modeling with machine learning: a survey. *ACM Computing Surveys*, 55(1), 1–34. <https://doi.org/10.1145/3477344>

7. RESPONSABILIDADE PELAS INFORMAÇÕES

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