

## Sistema para Autocalibração Adaptativa de Braços Robóticos com Sensores e Aprendizado de Máquina de Baixo Custo

Déborah C. Lopes\*, João L. Vilar-Dias\*\*,  
Fernando B. Lima-Neto\*\*\*, Luis A. Gómez-Malagón\*\*\*\*

*Escola Politécnica de Pernambuco, Universidade de Pernambuco,  
Pernambuco, Brasil*

\* e-mail: dcl1@poli.com

\*\* e-mail: jlvd@ecomp.poli.br

\*\*\* e-mail: fbln@ecomp.poli.br

\*\*\*\* e-mail: lagomezma@poli.br

**Abstract:** Robotic arms calibration is an important and necessary activity for an effective use of this kind of equipment in industry. However, the standard technics demand expensive equipment and many work hours of highly-qualified professionals. This research work presents a device and a methodology for self-calibration of robotics arms. Such methodology must be self-adaptive, fast and low cost. The proposed system allows the periodic calibration of already installed robots in the work environment using inertial sensors, electronic compass and a machine-learning algorithm of low computational cost that can run inside of ordinary microcontrollers. This methodology was tested in a robotic platform, composed by a 6 DOF spherical robot without any previous calibration. The results show that using the presented method, the robot's calibration can be performed efficiently after few interactions, reaching an accuracy of 1°. In addition, it can help to identify failures in the robot's shafts.

**Resumo:** A calibração de braços robóticos é uma atividade crucial para utilização efetiva desses equipamentos na indústria. No entanto, as técnicas tradicionais envolvem equipamentos de alto custo, muitas horas de engenharia e profissionais altamente qualificados. Sendo assim, o presente trabalho propõe um dispositivo e uma metodologia para autocalibração de braços robóticos. Tal metodologia deve ser adaptativa, rápida e de baixo custo. O sistema proposto permite a calibração periódica de robôs já instalados no ambiente de trabalho, usando sensores inerciais, bússola eletrônica e algoritmo de aprendizagem de máquina de baixo custo computacional que pode rodar em microcontroladores comuns. A metodologia foi testada em uma plataforma robótica, contendo um robô esférico de 6 eixos e sem calibração prévia. Os resultados mostram que por meio desta, a calibração pode ser feita eficientemente, em poucas iterações e com acurácia de 1°. Isso além de poder auxiliar no diagnóstico de falhas nos eixos.

**Keywords:** robotics; robotic arm; machine learning; calibration; industry 4.0.

**Palavras-chaves:** robótica; braço robótico; aprendizado de máquina; calibração; indústria 4.0.

### 1. INTRODUÇÃO

Braços robóticos são tradicionalmente utilizados cada vez mais nas indústrias de classe mundial. Eles são muito necessários em tarefas de movimentos repetitivos com uma ampla gama de aplicação, e.g. pintura, soldagem e montagem (Wang et al. 2015). Como requisitos, estes dispositivos necessitam apresentar força e velocidade de deslocamento compatíveis com a atividade, assim como exatidão no posicionamento que atenda aos requisitos de montagem e qualidade da aplicação.

Os movimentos desses robôs são calculados por meio de equações complexas, por exemplo, a partir da padronização de Denavit-Hartenberg (DH) (Paul, R. P. 1981), para as quais, são usados constantes de projeto, que são o comprimento de cada eixo, deslocamentos fixos (*offsets*) e angulações. No entanto, as equações são desenvolvidas para o modelo ideal de robô e uma vez que essas constantes divergem sensivelmente entre cada robô fabricado, o posicionamento da ponta da ferramenta, durante o trabalho do robô, pode divergir da posição calculada,

apresentando um erro de posição (Švaco et al. 2014). Além do mais, variações geométricas podem acontecer por folgas nas engrenagens e na montagem das articulações, assim como por deformações devido a altas cargas. Essas diferenças podem ser definidas como erros não geométricos e necessitam de calibrações que envolvam cálculos não lineares para sua compensação (Wang et al. 2019).

Com o intuito de solucionar esse problema, diversas técnicas de calibração e de medição de erros de posicionamento foram propostas. Alguns estudos utilizaram uma esfera como referência para realizar a calibração, movendo a terminação do robô sobre esta e usando as posições encontradas para calibrar os eixos por meio de equações cinemática inversa (Sun et al. 2009). Outros estudos utilizaram também sensoriamento a laser (Zhuang et al. 1992) ou por meio de câmeras (Cooperstock & Milios 1992) (Švaco et al. 2014). Neste último, duas câmeras perpendiculares foram postas sobre a área de trabalho do robô, que move sua ponta sobre a esfera de referência. Em estudo mais recente, é utilizada uma câmera do tipo RGB-D posicionada sobre a ferramenta, a fim de realizar

a calibração e o mapeamento 3D do ambiente, a câmera fotografa o ambiente em uma sequência de poses com variações de 5° e calcula as variações usando de cinemática inversa (Li et al. 2019).

As técnicas mencionadas acima são caracterizadas como calibração off-line, na qual os cálculos para minimização dos erros são feitos com dados medidos por movimentos realizados anteriormente. No entanto, caso o robô tenha uma variação considerável de carga ou ambiente, como alta temperatura ou alta pressão causando dilatação das peças, a calibração por dados prévios se torna obsoleta, sendo necessária uma nova calibração, que pode ser trabalhosa e demorada. Dessa forma, métodos de calibração online, que pode ser feita rapidamente, nos mais diversos ambientes, se torna uma técnica indispensável (Du et al. 2015).

Um método online usando uma câmera infravermelha e quatro marcadores infravermelhos para referenciar a o deslocamento do robô e da ferramenta é proposto para calibração de robôs cirúrgicos (Yuan et al. 2020). Essa técnica consiste no cálculo das matrizes de transferência entre o eixo de coordenada do robô e da câmera e entre a ferramenta e o instrumento de referência. Sendo capaz de calibrar o robô em apenas quatro movimentos.

Um estudo propõe a autocalibração de um robô biologicamente inspirado, a fim de reduzir o trabalho humano sobre o processo de calibração. Neste estudo, o robô é autocalibrado usando combinações de equações lineares diferenciais, encontrando a matriz jacobiana que multiplica as entradas a fim de obter o movimento calibrado. Essa técnica simples obteve redução do erro de 4,08 mm para 0,12 mm para junta do cotovelo (Mustafa et al. 2008).

Outra técnica sugerida para calibração foi usando um par de ferramentas metálicas, na qual, uma delas contendo uma meia esfera oca é fixa na ponta do robô e a outra ferramenta contém três esferas magnéticas fixas ao chão. Nessa proposta é necessário que seja feito o posicionamento manual do robô para chegar nas três esferas de referência, para que este saiba as posições de cada uma delas. A rotina de calibração acontece para cada uma das esferas, nesse processo o robô tenta pôr a ferramenta em uma esfera por vez e o acoplamento é ajustado pela força magnética entre as ferramentas, a partir disso, o robô move a ponta em torno da esfera guardando 625 posições em torno de cada uma delas, gerando combinações que serão usadas para os cálculos de ajuste de coordenadas e calibração (Nadeau et al. 2019).

Sensores inerciais foram a priori utilizados, por exemplo, na biomecânica, para identificação de movimentos, tais como marcha humana (Caldas et al. 2018) ou movimentos dos membros superiores (Prayudi & Kim 2012). Com essa lógica, foi usado uma unidade de medida inercial (IMU) com acelerômetro, giroscópio e magnetômetro posicionado sobre a garra, além de um sensor de posição, a fim de captar o deslocamento de braços robóticos para realizar a sua calibração de maneira online. Essa proposta encontrou bons resultados de acurácia, além de conveniência na facilidade da implementação, mas ainda necessita de cálculos de DH e cinemática inversa (Du et al. 2015).

Pesquisas também vêm sendo realizadas a fim de utilizar de técnicas de inteligência artificial (IA) para posicionamento do robô (Cooperstock & Milios 1992)(Kuperstein, M. 1987), com o intuito de substituir a análise de DH e cinemática inversa, uma vez, que os algoritmos de IA não necessitam de dados sobre a estrutura física do robô e por consequente, também não necessitam de calibração após o treinamento da IA. Quando técnicas de redes neurais são utilizadas, o aprendizado se dá pela atualização dos pesos após o posicionamento da ferramenta e leitura do erro para cada posição (Kuperstein, M. 1987). Por outro lado, essas técnicas exigem um tempo elevado de treinamento, no qual são realizadas inúmeras iterações, além de necessitar de excelente e rápido sensoramento sobre toda a área de trabalho da ferramenta. Isso porque, as Redes Neurais são conceitualmente aproximadores universais de funções, em sua essência, e a acurácia das posições encontradas dependem diretamente do número de iterações que aumenta com a complexidade do sistema (e.g. dada pelo número de juntas do robô e relações entre os sensores).

Usando técnicas de aprendizado de máquina por reforço e sensores também é possível realizar a calibração de braços robóticos. Por exemplo, recentemente foi proposto que um robô pode ser autocalibrado ou calibrado com o auxílio de um operador leigo, ainda que o robô não conheça nada sobre o ambiente, usando de aprendizado por reforço e sensores capazes de observar o ambiente como o conjunto de uma câmera e um sensor inercial (Nobre & Heckman 2020).

Abordagens híbridas que consistem no uso simultâneo de técnicas de cinemática inversa e algoritmos de aprendizagem de máquina também foram utilizadas em estudos anteriores. Por exemplo foi realizada uma divisão dos ângulos por área de trabalho de acordo com a carga do robô, e treinada uma rede neural. Nessa proposta, os ângulos de rotação das juntas são calculados por meio de cinemática inversa e usados como entrada de uma rede neural com uma camada escondida. A rede neural tem por objetivo corrigir os erros não geométricos usando da função tangente-sigmoide para ativação dos neurônios da camada intermediária. Os resultados mostram uma redução do erro de 17 cm para 4,5 cm (Wang et al. 2019). Também podem ser usados algoritmos de otimização como *Particle Swarm Optimization* (PSO) a fim de encontrar a melhor calibração uma vez já calculados os erros e os ângulos das juntas pela cinemática inversa; nessa abordagem pode ser usadas redes neurais para modelar o cálculo da calibração e, após o treinamento, não ser mais necessário o uso do algoritmo de otimização (Kuo et al. 2016).

Diante do cenário apresentado, e após exaustiva revisão da literatura, até o presente momento não foram reportadas técnicas para autocalibração de braços robóticos que sejam rápidas, de baixo custo e sem a necessidade de mão de obra altamente especializada. Também não estão disponíveis técnicas adaptativas, com as quais os robôs possam aprender e se readaptar, mudando seus parâmetros de calibração diante do desgaste de peças, motores, falta de lubrificação ou outros problemas eletromecânicos.

Além disso, alguns requisitos para técnicas de calibração de braços robóticos são acurácia, repetitividade e boa resolução

(Conrad et al. 2000), por estes motivos, também é importante assegurar a acurácia após a instalação, de forma que esses sistemas possibilitem a calibração online, após a instalação do robô, onde ele será usado. Ser de baixo custo, rápido e de fácil implementação também são requisitos importantes para atender pequenas fábricas e escolas técnicas, assim como adaptação é um requisito interessante para manutenção contínua de robôs usados.

Sendo assim, o presente trabalho apresenta um equipamento e uma metodologia de calibração rápida, que possa ser realizada automaticamente, ou como ferramenta de auxílio para o calibrador, e ainda seja online, de baixo custo e rápida implementação. Isso possibilita calibrações periódicas e auxilia sobremaneira na manutenção do robô.

A metodologia contempla uma ordem de movimentos para a calibração, assim como um algoritmo adaptativo, rápido e de fácil implementação, baseado em redes neurais simples do tipo ADALINE, para que possa ser realizado por controladores de pouco processamento, como microcontroladores comuns. O equipamento construído para a calibração, por sua vez, é composto de apenas 3 sensores inerciais (acelerômetro e giroscópio) e uma bússola magnética para medição do deslocamento angular e, além disso, 3 sensores magnéticos de fim de curso para posicionamento do robô para calibração.

O sistema desenvolvido foi testado num robô esférico de 6 eixos e permite a calibração inteligente e rápida de braços robóticos novos e usados em ambiente fabril, por profissionais com pouca instrução dispensando a necessidade de cinemática inversa.

## 2. FUNDAMENTAÇÃO TEÓRICA

O sistema adaptativo de aprendizagem dos coeficientes de calibração apresentado nesse trabalho, foi desenvolvido baseado nas redes ADALINE, devido a sua simplicidade e baixa exigência computacional para que possa ser treinada em tempo real por microcontroladores. As redes ADALINE são algoritmos de computação inteligente capazes de realizar classificações ou regressões simples e de baixo consumo computacional, que usam de neurônios artificiais, sendo um por saída (Valença, M. 2007). Essas redes podem usar de uma função contínua, como a função linear ou sigmoide, para representar a saída de seus neurônios. Uma rede do tipo ADALINE com um único neurônio (saída) pode ser representada pela Equação 1, na qual a saída da rede,  $y$ , é a resposta de uma função de ativação,  $f$ , cuja entrada é a soma do produto dos pesos,  $w$ , por cada entrada da rede,  $x$ , assim:

$$y = f(w_0 \cdot x_0 + w_1 \cdot x_1 + \dots + w_n \cdot x_n) \quad (1)$$

Os pesos por sua vez podem ser ajustados de acordo com a Equação 2, sendo:

$$w_{i(novo)} = w_{i(antigo)} + \alpha(d_j - y_j) \cdot x_j \cdot f'(w_0 \cdot x_0 + w_1 \cdot x_1 + \dots + w_n \cdot x_n) \quad (2)$$

Onde  $i$  representa o número da entrada,  $\alpha$  é o coeficiente de aprendizagem,  $d$  a saída desejada,  $y$  a resposta encontrada pela

rede para cada iteração,  $j$ , e  $f'$  é a derivada da função de ativação (Valença, M. 2007).

Esse tipo de rede pode ser usado para criar um sistema de aprendizado adaptativo no qual o novo peso é atualizado em função do erro, que é a diferença entre o valor desejado e o valor medido, e do coeficiente de aprendizagem, que pode ser considerado como a taxa de esquecimento do peso antigo e atualização em função das novas medições.

## 3. METODOLOGIA

A fim de captar a movimentação do robô, foi desenvolvido um dispositivo de sensoriamento, composto por 3 sensores inerciais do tipo GY-521 (Robotpark. 2015a) e uma bússola magnética do tipo GY-271 (Robotpark. 2015b). O sistema também dispõe de 3 sensores magnéticos de fim de curso, para servir de referência aos sensores inerciais; 3 LEDs e um buzzer informativos como mostrado na Figura 1.

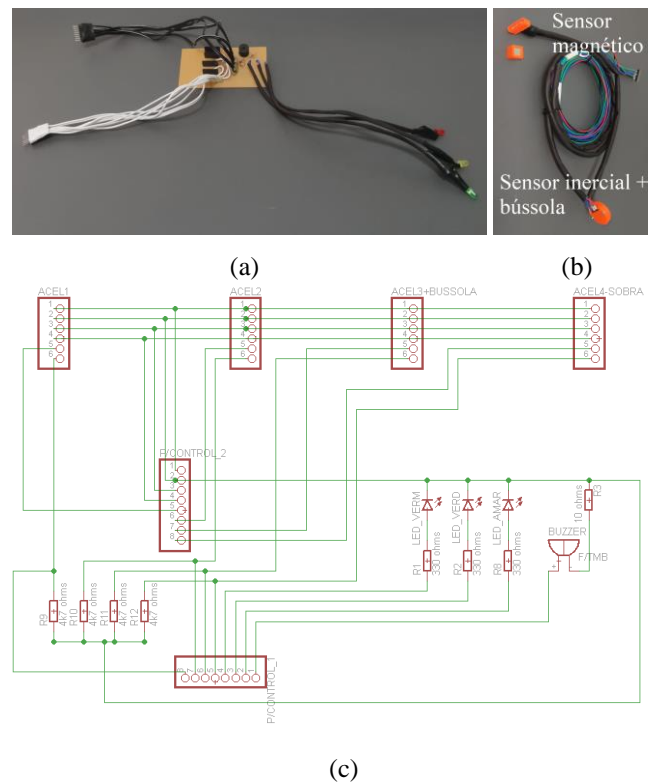


Fig. 1 - Dispositivo de Sensoriamento. (a) placa de circuito para interface dos sensores com o microcontrolador, (b) conjunto de sensoriamento contendo um sensor inercial, a bússola e um sensor magnético, (c) esquemático da placa. Fonte: (autor).

Os sensores inerciais utilizados são compostos por acelerômetros e giroscópios de 3 eixos, além de um sensor de temperatura. No entanto, a medida de posição obtida pelo giroscópio não é acurada, pois o sensor mede a aceleração angular instantânea, acrescida de erro e *offset* e que necessita ser integrada para encontrar a velocidade e novamente integrada para calcular a posição, apresentando assim um erro cumulativo com o tempo, sendo necessários filtros com alto consumo computacional para sua minimização (Alam et al. 2014), como o filtro de Kalman, mas que pode apresentar erros

na medição devido a filtragem (Kim & Bang, 2018) e que em testes preliminares reduziu a acurácia da leitura dos ângulos. Ainda assim, a leitura dos ângulos pode ser obtida de maneira mais acurada e sem custo computacional, usando a decomposição vetorial da gravidade nos eixos do espaço, sendo, contudo, sensível à vibração, podendo apresentar ruído (Albaghdadi & Ali 2019). Porém a variação angular em torno do eixo da gravidade (*yaw*) não pode ser calculada por essa técnica e não apresenta uma acurácia adequada para calibração dos eixos de um robô. A calibração desses sensores foi realizada usando ângulos de referência conhecidos e com auxílio da biblioteca, para Arduino, *mpu6050.h* (Eletronic Cats, 2019). Por isso, para ajuste das juntas rotativas em torno do eixo da gravidade é utilizada a bússola magnética, cuja principal dificuldade é a interferência magnética do ambiente e dos motores energizados, devido a isso, ela precisa ser recalibrada como descrito em (Advanced Safety Devices, 2020) a cada aplicação, com os motores do robô energizados. Com a metodologia usada é possível verificar uma acurácia de pelo menos 1°, que foi validada por medições manuais.

Para realização dos experimentos foi utilizada uma plataforma robótica de 6 eixos, sem calibração prévia, adaptada a partir do BCN3D Moveo de 5 DOF (BCN3D Technologies, 2020). Para controle do robô, assim como a rotina de movimentação e calibração inteligente é utilizada o ambiente de desenvolvimento integrado do Arduino e um Arduino Mega, escolhido pelo seu baixo custo e elevado número de portas (Arduino, 2020).

Os sensores inerciais foram posicionados em cada conjunto de juntas de rotação e flexão, a fim de captar o movimento, e foram dispostos ao final ou meio dos links como proposto em estudos anteriores (Wijayasinghe et al. 2017). A disposição dos sensores é apresentada na Fig. 2.

### 3.1 Rotina de Aprendizagem

Para evitar que os ruídos e interferências na leitura dos acelerômetros e da bússola causem erros na medição, a aprendizagem é baseada apenas nos deslocamentos dos eixos. Ou seja, a diferença entre a posição imediatamente antes e um tempo pequeno (usamos 4 s) após a realização do movimento, isso com o intuito de garantir a estabilidade do sinal lido. E como regra, sempre que é requisitado para um dos eixos se deslocar angularmente, é lida a posição nos sensores antes e após o movimento. Caso o deslocamento realizado seja diferente do desejado o sistema então aprende (i.e., atualiza variável de aprendizagem) e manda o eixo se mover novamente. Mas neste caso somente o ângulo restante (seja no sentido horário ou anti-horário) a fim de corrigir o erro. Isso se repete até que todo o deslocamento desejado inicialmente tenha sido realizado e o eixo tenha chegado à posição solicitada.

O reajuste da variável de aprendizagem é realizado por meio da Equação 3, sendo:

$$V_a = V_{a\text{ ant}} + d \cdot \alpha \quad (3)$$

onde  $d$  é o delta entre o deslocamento desejado e o alcançado,  $\alpha$  é um coeficiente de aprendizagem pré-estabelecido,  $V_a$  é a variável de aprendizagem atualizada e  $V_{a\text{ ant}}$  é a variável de aprendizagem anterior.




Fig. 2 - Disposição dos Sensores. Fonte: (autor).

A Equação 3 é utilizada a cada iteração e  $V_a$  é reajustada sempre que o deslocamento medido pelos sensores é diferente do deslocamento desejado para o robô dentro de um erro admissível máximo. Sendo, por sua vez, acrescida quando o delta é positivo, e decrescida quando delta é negativo. Dessa forma a variável de aprendizagem funciona como um peso em uma rede ADALINE, sendo necessária uma rede independente, assim como uma variável de aprendizagem, para cada junta.

A variável de aprendizagem é usada com base na Equação 4, como multiplicador do deslocamento desejado do motor,  $d_d$ , a fim de encontrar deslocamento ajustado do motor,  $d_a$ , e necessário para alcançar a posição alvo do eixo dentro de uma margem de segurança estabelecida, sendo  $d_d$  e  $d_a$  medido em passos, assim:

$$d_a = d_d \cdot V_a \quad (4)$$

Um comando de movimento só finaliza quando todo o deslocamento solicitado é realizado, dessa forma, se o calibrador ou algoritmo automático ordenar um deslocamento de 10° na junta e o robô se mover diferente disso, o sistema de aprendizagem calcula o erro e ordena um novo deslocamento no sentido necessário, repetindo isto enquanto não atingir o objetivo. A rotina de aprendizagem é ilustrada no diagrama da Fig. 3.

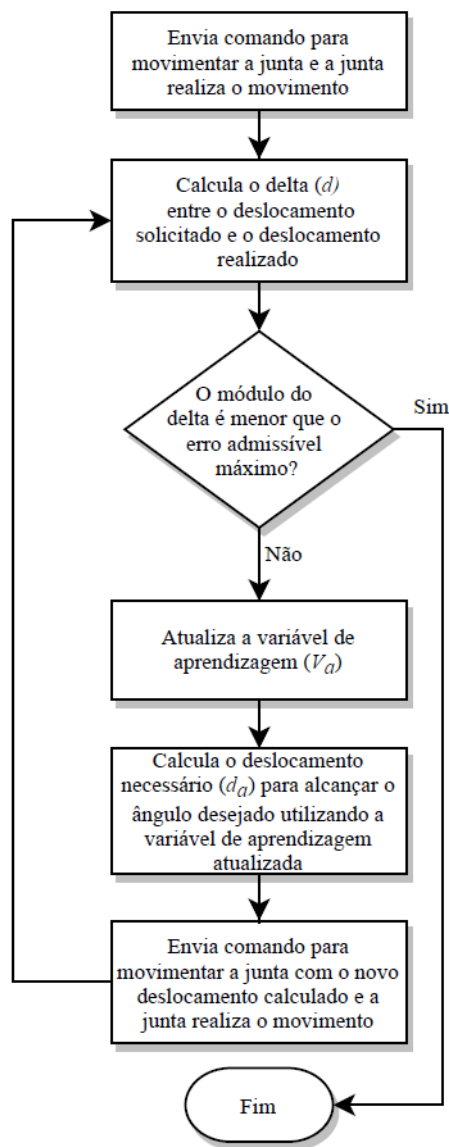


Fig. 3 – Diagrama da rotina de Aprendizagem. Fonte: (autor).

### 3.2 Rotina de Calibração

Para que a variável de aprendizagem ideal seja aprendida, deve ser enviada uma quantidade suficiente de movimentos, separadamente, para cada eixo. Por segurança, é necessário iniciar por deslocamentos curtos, uma vez que, se a junta estiver excessivamente descalibrada, comandos de movimentos angulares longos podem resultar em deslocamentos exagerados e bruscos que causem dano ao robô ou ao ambiente. Uma vez iniciado o treinamento por movimentos curtos, em seguida serão executados progressivamente movimentos angulares mais longos, que são usados a fim de acelerar a aprendizagem e garantir que a acurácia esperada vale para todas amplitudes de movimento.

Por tanto, a rotina de calibração segue os seguintes passos:

1. Robô na posição vertical inicial, onde todos os ângulos de junta são considerados  $0^\circ$  e os sensores magnéticos imediatamente acusam presença;

2. Selecionar o eixo;
3. Teste  $20^\circ$ : Deslocar da posição  $0^\circ$  para  $10^\circ$ ; seguido de deslocamento de  $10^\circ$  para  $-10^\circ$  e retornando para  $0^\circ$ ;
4. Teste  $40^\circ$ : Deslocar da posição  $0^\circ$  para  $20^\circ$ ; seguido de deslocamento de  $20^\circ$  para  $-20^\circ$  e retornando para  $0^\circ$ ;
5. Teste  $60^\circ$ : Deslocar da posição  $0^\circ$  para  $30^\circ$ ; seguido de deslocamento de  $30^\circ$  para  $-30^\circ$  e retornando para  $0^\circ$ ;
6. Repetir passo 5 (Teste  $60^\circ$ );
7. Repetir passo 4 (Teste  $40^\circ$ );
8. Repetir passo 3 (Teste  $20^\circ$ );
9. Se o erro estiver abaixo da acurácia estabelecida, e o último passo tenha sido completo com apenas um movimento do robô, avançar para o passo 10, se não, retornar para o passo 3, realizando mais uma vez a sequência de movimentos. Caso já tenham sido realizadas múltiplas execuções dos passos 3 ao 8, e ainda assim, não haja convergência da variável de aprendizagem, também seguir para o passo 10.
10. Repetir a partir do passo 3 para os demais eixos, indo do mais proximal para a mais distal da base.

Nesta rotina são realizados movimentos nas duas direções das juntas, horária e anti-horária, e com amplitudes crescentes, sendo a mínima de  $10^\circ$  e a máxima de  $60^\circ$ . Caso sejam necessárias múltiplas execuções dos passos 3 ao 8 para um mesmo eixo e ainda assim, esse não seja calibrado, é possível que esse contenha algum defeito eletromecânico e necessite de manutenção. Por isso, a técnica proposta também pode ser útil para detecção de falhas em juntas robóticas.

## 4. RESULTADOS

A rotina de autocalibração proposta na seção anterior foi realizada para cada eixo do robô e foram medidos os erros entre as posições desejadas e as posições obtidas, assim como a variável de aprendizagem em cada iteração. O coeficiente de aprendizagem para treinamento foi escolhido empiricamente com o valor de 0,05 e definido o erro admissível máximo de  $1^\circ$  para o ângulo final desejado.

Nas Fig. de 4 a 9, é mostrado, para cada eixo do robô, os gráficos de barras com a quantidade de iterações necessárias para a realização de cada deslocamento desejado durante a sequência de calibração, seguido da soma do total de iterações para aquele bloco de comandos (3 últimos dados), e os gráficos da variável de aprendizagem para cada número dos movimentos realizados para a calibração.

O treinamento foi concluído uma vez que ao final de um ciclo a variável de aprendizagem tenha se mantido constante nas últimas duas iterações, a fim de não alongar os testes, mas ainda assim tornando possível uma conclusão sobre a eficácia do método e a condição eletromecânica do eixo.

Quanto maior a quantidade de iterações para realizar um movimento significa que mais descalibrado está este eixo. A tendência é que o número de iterações seja reduzido à medida que a variável de aprendizagem é atualizada, até o ponto em que é encontrado um valor ótimo e todo o deslocamento necessário é realizado em um único movimento. Também foi observado que, por vezes, durante o treinamento e, ainda com a variável de aprendizagem longe do valor final, foi possível realizar o movimento desejado em poucas iterações (uma ou duas), mas, nestes casos, foi encontrado um alto erro ou um erro próximo do limite admissível, no entanto, estes ainda foram reduzidos ao encontrar o valor ótimo da variável de aprendizagem.

Analisando os gráficos de barras é perceptível que a quantidade de movimentos por deslocamento desejado diminui com o passar das iterações, fazendo o robô ser capaz de realizar todo o deslocamento desejado, em apenas um movimento, o que é um claro indicador de calibração do eixo.

Por meio dos gráficos de linha, que mostram a variável da aprendizagem, pode-se notar que a variável de aprendizagem varia rapidamente no começo do treinamento, uma vez que os eixos estão descalibrados, e a medida que o número de movimentos cresce a variável de aprendizagem tende a estabilizar, mantendo-se aproximadamente constante para quase todos os eixos. As variáveis de aprendizagem que aumentam indicam que a quantidade de passos do motor configurada para um ciclo do eixo estava abaixo do necessário, e quando a variável de aprendizagem diminui indica que a quantidade de passos do motor configurada para um ciclo do eixo estava acima do necessário.

Os eixos 1, 2, 4 e 5 apresentaram estabilização da variável de aprendizagem ao final do treinamento realizado. Além disso, ao longo do treinamento foi notado que estes eixos reduzem a quantidade de movimentos necessários para realizar o deslocamento desejado e ao final do treinamento realizam o movimento angular desejado em apenas uma tentativa, atendendo assim a expectativa de calibração.

Apenas o eixo 3 não conseguiu atingir seu ponto ótimo, tendo ainda alta variabilidade nos últimos movimentos. No entanto, em análise posterior, foi encontrada folga no eixo, o que impossibilitou uma variável de aprendizagem fixa. Além do eixo 3, outro eixo que apresentou problemas na calibração foi o eixo 6, onde a variável de aprendizagem ficou oscilando entre 2,53 e 2,43 e não foi possível determinar com certeza qual seria seu valor ótimo. No entanto para este eixo foi observado que era necessária uma variável maior quando realizado o treinamento para os ângulos maiores e uma variável menor para os menores, o que é um possível indicador de problemas de atrito dinâmico, podendo ser devido a problemas nas superfícies das peças decorrentes do processo de manufatura.

Por meio da análise dos gráficos é possível verificar eixos defeituosos e até mesmo traçar um perfil para a causa desses defeitos, como excesso de atrito estático, motor subdimensionado, corrente máxima insuficiente, etc., quando a dificuldade de calibração se dá para movimentos curtos; excesso de atrito dinâmico, como por baixa lubrificação, etc.

quando a dificuldade acontece para às altas amplitudes de deslocamento. Defeitos também podem ser verificados caso erros sejam consideravelmente maiores para um dos sentidos de rotação.

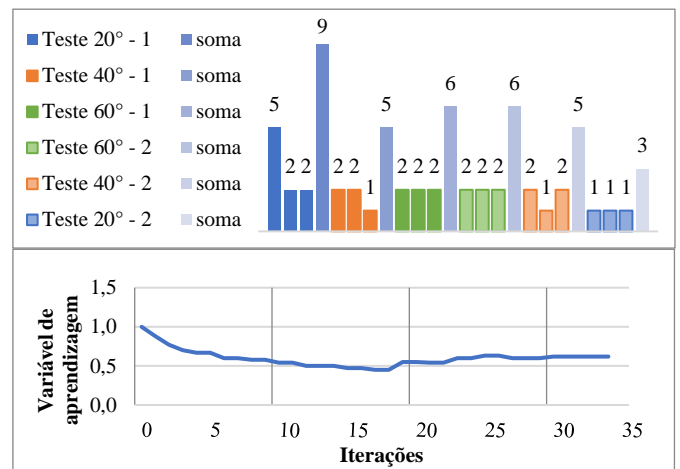


Fig. 4 - Dados do teste para o eixo 1. Fonte: (autor).

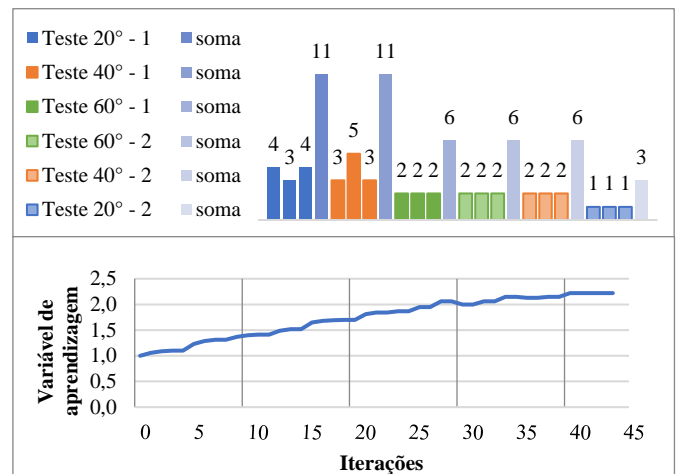


Fig. 5 - Dados do teste para o eixo 2. Fonte: (autor).

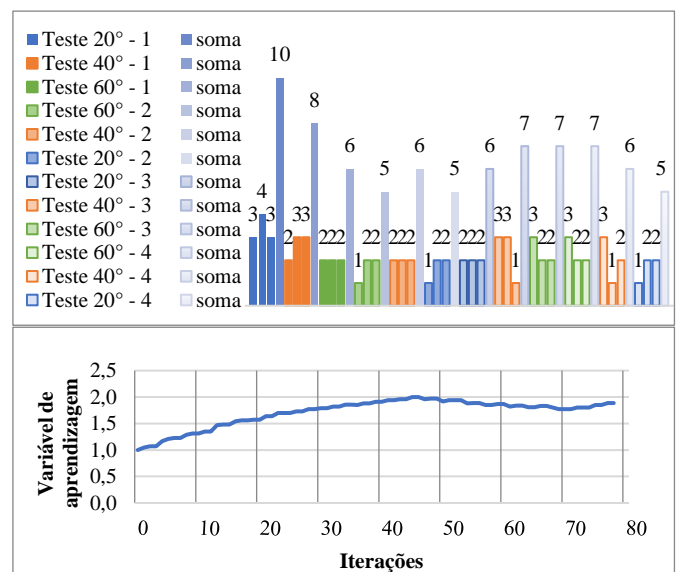


Fig. 6 - Dados do teste para o eixo 3. Fonte: (autor).

## 5. CONCLUSÃO

Os testes realizados foram capazes de validar com sucesso a técnica proposta, além disso foi verificado que o uso conjunto de sensores inerciais e bússolas eletrônicas de baixo custo atendem às exigências para calibração de robôs industriais.

A quantidade de movimentos definidos para o ciclo de treinamento se mostrou suficiente para calibrar a maioria dos eixos de um robô, em apenas um ciclo e com acurácia de 1°; ainda que este robô não tenha passado por calibração prévia. Um impedimento encontrado neste trabalho para redução da acurácia durante os testes é que o robô utilizado possui limitação de passo de 1.8° no eixo 4. Esse valor de acurácia pode ser ainda menor, caso a acurácia dos sensores para valores mais baixos seja garantida e o robô a ser calibrado tenha motores e eixos hábeis de atender movimentos inferiores a 1°.

Também pode-se verificar que a metodologia proposta é eficiente para encontrar problemas eletromecânicos. De forma que se o sistema inteligente aprende como completar com exatidão um movimento para uma dada amplitude e região, mas que esse mesmo aprendizado não atende bem outras amplitudes ou regiões de deslocamento para o mesmo eixo, ou seja, a variável de aprendizagem não converge durante o processo de calibração, é um indício de que há alguma folga, desgaste ou outra falha eletromecânica no eixo que está impossibilitando a exata completude do movimento.

Os experimentos também mostraram que o uso de sistemas baseados em aprendizado de máquina, podem ser aplicados com sucesso em microcontroladores tradicionais de baixo custo e reduzido poder computacional. Essas técnicas se apresentam de maneira promissora e eficazes para futuras aplicações na indústria 4.0, reduzindo consideravelmente as horas de engenharia gastas em atividade que poderiam ser eficientemente realizadas por máquinas inteligentes.

É possível, no entanto, afim de se obter um sistema mais preciso, utilizar técnicas mais complexas de aprendizado de máquina, em combinação com aparatos computacionais mais potentes, para contornar erros não lineares, como Redes Multicamadas com funções de ativação não lineares. Também pode ser vantajoso identificar constantes que possam solucionar o problema do atrito estático; ou ainda encontrar diferentes variáveis de aprendizagem que atuem sobre partes do movimento do eixo, mas levando em conta o ângulo total a ser percorrido para realizar melhores aproximações de acordo com a direção do movimento.

Por fim, o sistema proposto pode ser testado em campo e com robôs de diferentes estruturas e idades com o intuito de relacionar as variáveis de aprendizagem com o histórico de manutenção dos equipamentos.

## AGRADECIMENTOS

O presente trabalho foi realizado com apoio da Coordenação de Aperfeiçoamento de Pessoal de Nível Superior – Brasil (CAPES) – Código de Financiamento 001.

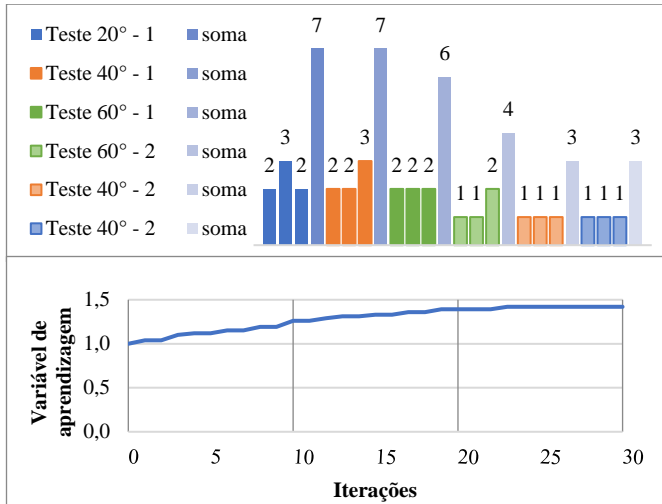


Fig. 7 - Dados do teste para o eixo 4. Fonte: (autor).




Fig. 8 - Dados do teste para o eixo 5. Fonte: (autor).

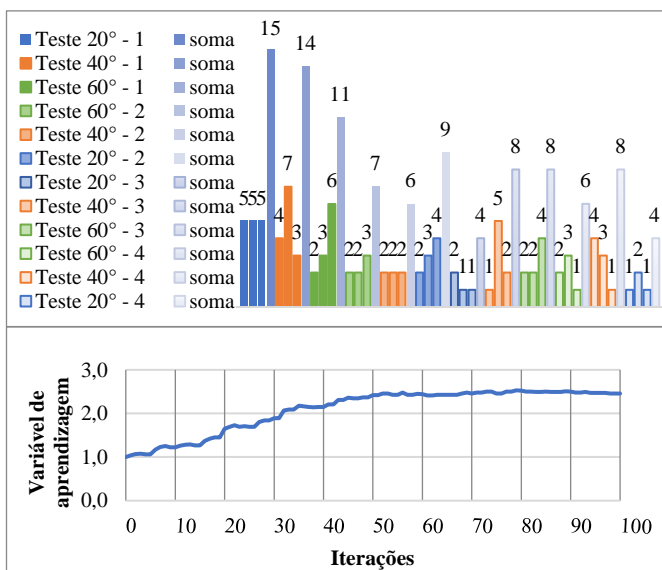


Fig. 9 - Dados do teste para o eixo 6. Fonte: (autor).

## REFERÊNCIAS

- Advanced Safety Devices. (2020). *How Does A Digital Compass Work? - ASD*. [online] Available at: <<https://www.safety-devices.com/how-does-digital-compass-work-a-12.html>> [Accessed 4 June 2020].
- Alam, F., ZhaiHe, Z., & JiaJia, H. (2014). A comparative analysis of orientation estimation filters using MEMS based IMU. In: *Proceedings of the International Conference on Research in Science, Engineering and Technology*, Dubai, UAE, p. 21-22.
- Albaghdadi, A. F., & Ali, A. A. (2019). An Optimized Complementary Filter For An Inertial Measurement Unit Contain MPU6050 Sensor. *Iraqi Journal for Electrical And Electronic Engineering*, v. 15, n.2, p. 71-77.
- Arduino. (2020). *Arduino Mega 2560 Rev3 | Arduino Official Store*. [online] Available at: <<https://store.arduino.cc/usa/mega-2560-r3>> [Accessed 4 June 2020].
- BCN3D Technologies. (2020). *BCN3D MOVEO - A Fully Open Source 3D Printed Robot Arm - BCN3D Technologies*. [online] Available at: <<https://www.bcn3d.com/bcn3d-moveo-the-future-of-learning/>> [Accessed 4 June 2020].
- Caldas, R., Rátiva, D., & de Lima Neto, F. B. (2018). Clustering of Self-Organizing Maps as a means to support gait kinematics analysis and symmetry, *Medical engineering & physics*, v. 62, p. 46-52.
- Conrad, K.L., Shiakolas, P.S. and T. C. Y. (2000). Robotic Calibration Issues: Accuracy, Repeatability And Calibration. In: *Proceedings of the 8th Mediterranean Conference on Control and Automation (MED2000)*. Greece.
- Cooperstock, J. R., & Milios, E. E. (1992). Adaptive neural networks for vision-guided position control of a robot arm. In: *Proceedings of the 1992 IEEE International Symposium on Intelligent Control*, p. 397-403.
- Du, G., Zhang, P., & Li, D. (2015). Online robot calibration based on hybrid sensors using Kalman Filters. *Robotics and Computer-Integrated Manufacturing*, v. 31, p. 91-100.
- Electronic Cats. (2019). *GitHub - ElectronicCats/mpu6050: MPU6050 Arduino Library*. [online] Available at: <<https://github.com/ElectronicCats/mpu6050>> [Accessed 9 September 2020].
- Kim, Y., & Bang, H. (2018). Introduction to Kalman filter and its applications. In: *Introduction and Implementations of the Kalman Filter*. IntechOpen.
- Kuo, P. H., Liu, G. H., Ho, Y. F., & Li, T. H. S. (2016). PSO and neural network based intelligent posture calibration method for robot arm. In: *2016 IEEE International Conference on Systems, Man, and Cybernetics (SMC)*, p. 003095-003100.
- Kuperstein, M. (1987). Adaptive visual-motor coordination in multijoint robots using parallel architecture. In: *Proceedings. 1987 IEEE International Conference on Robotics and Automation* v. 4, p. 1595-1602.
- Li, J., Ito, A., Yaguchi, H., & Maeda, Y. (2019). Simultaneous kinematic calibration, localization, and mapping (SKCLAM) for industrial robot manipulators. *Advanced Robotics*, v. 33 n. 23, p. 1225-1234.
- Mustafa, S. K., Yang, G., Yeo, S. H., Lin, W., & Chen, I. M. (2008). Self-calibration of a biologically inspired 7 DOF cable-driven robotic arm. *IEEE/ASME transactions on mechatronics*, v. 13, n. 1, p. 66-75.
- Nadeau, N. A., Bonev, I. A., & Joubair, A. (2019). Impedance control self-calibration of a collaborative robot using kinematic coupling. *Robotics*, v. 8, n. 2, p. 33.
- Nobre, F., & Heckman, C. (2020). Reinforcement learning for assisted visual-inertial robotic calibration, *Robotics Research*, p. 473-488. Springer, Cham.
- Paul, R. P. (1981). *Robot manipulators: mathematics, programming, and control: the computer control of robot manipulators*, The MIT Press.
- Prayudi, I., & Kim, D. (2012). Design and implementation of IMU-based human arm motion capture system. In: *2012 IEEE International Conference on Mechatronics and Automation*, p. 670-675.
- Robotpark. (2015a). *GY-521 MPU6050 6DOF 3-Axis Gyroscope And Accelerometer Module*. Available at: <<http://www.robotpark.com/GY-521-MPU6050-6DOF-3-Axis-Gyroscope-and-Accelerometer-Module?search=gy>> [Accessed 4 June 2020].
- Robotpark. (2015b). *GY-271 Electronic Compass*. Available at: <[http://www.robotpark.com/image/data/PRO/91457/GY\\_271\\_ELECTRONIC\\_COMPASS.pdf](http://www.robotpark.com/image/data/PRO/91457/GY_271_ELECTRONIC_COMPASS.pdf)>. [Accessed 4 June 2020].
- Sun, Y., Giblin, D. J., & Kazerounian, K. (2009). *Robotics and Computer-Integrated Manufacturing*, v. 25, n. 1, p. 204-210.
- Švaco, M., Šekoranja, B., Šuligoj, F., & Jerbić, B. (2014). Calibration of an industrial robot using a stereo vision system. *Procedia Engineering*, v. 3, p. 459-463.
- Valença, M. (2007). ADALINE. In: *Fundamentos das redes neurais: exemplos em Java*, p. 101-162, Livro Rápido, Recife.
- Wang, W., Liu, F., & Yun, C. (2015). Calibration method of robot base frame using unit quaternion form. *Precision Engineering*, v. 41, p. 47-54.
- Wang, Z., Chen, Z., Wang, Y., Mao, C., & Hang, Q. (2019). A robot calibration method based on joint angle division and an artificial neural network. *Mathematical Problems in Engineering*, v. 2019.
- Wijayasinghe, I. B., Sanford, J. D., Abubakar, S., Saadatzi, M. N., Das, S. K., & Popa, D. O. (2017). Optimal accelerometer placement on a robot arm for pose estimation. In: *Smart Biomedical and Physiological Sensor Technology XIV*, International Society for Optics and Photonics, v. 10216, p. 102160B.
- Yuan, H. X., Li, Q. Q., Zhao, H., Wang, L. J., & Song, R. (2020). An Automatic Calibration Method for Puncture Surgical Robot. In: *IOP Conference Series: Materials Science and Engineering*, v. 717, n. 1, p. 012008.
- Zhuang, H., Li, B., Roth, Z. S., & Xie, X. (1992). Self-calibration and mirror center offset elimination of a multi-beam laser tracking system. *Robotics and autonomous systems*, v. 9, n. 4, p. 255-269.