


Inverse Differential Control of a 6-Dof Parallel Manipulator Using Neural Networks

التحكم بمنصة تفرعية سداسية الأذرع من خلال النموذج التفاضلي العكسي بالاستعانة بالشبكات العصبونية

م. علاء الدين جمعة : المعهد العالي للعلوم التطبيقية والتكنولوجيا - دمشق - سورية.
 د. شادي بيطار: المعهد العالي للعلوم التطبيقية والتكنولوجيا - دمشق - سورية.
 د. آصف جعفر: المعهد العالي للعلوم التطبيقية والتكنولوجيا - دمشق - سورية.
 المؤلف الرئيس: alaaaldeen.joumah@hiast.edu.sy

ABSTRACT

This research presents an algorithm for modeling and controlling a trajectory tracking problem for a 6-dof (degree of freedom) parallel platform using inverse differential modeling aided by neural networks. The algorithm addresses the issues of model uncertainty and adaptation to changes and external disturbances within the surrounding environment. By employing the algorithm of Particle Swarm Optimization (PSO), the initial weight values of the neural network are determined, along with the optimal network structure required for estimating the differential model. This is done to achieve the best network performance with minimal training time. Subsequently, the network is trained using a comprehensive training dataset that covers the entire workspace of the platform, without of having to know the geometric configuration or mathematical model of the robotic manipulator. The trained network is then utilized within the control loop to drive the parallel platform in a reference trajectory tracking problem. The acquired data during platform operation is used to retrain the neural network, enabling it to adapt to changes occurring within the system. The simulation results demonstrated the effectiveness of the proposed algorithm in the problem of reference path tracking by enhancing performance and adapting to changes occurring in the overall platform. The proposed model was able to reduce tracking error by an average of 92.2%, assuming differences in the length of one of the platform's arms, as well as an average reduction of 27.3% assuming the presence of mechanical backlash within the platform actuators. Furthermore, the proposed algorithm exhibited robustness against noise and external disturbances. **Keywords:** parallel platform, inverse differential model, trajectory tracking, neural networks, particle swarm optimization.

المخلص

يُطرح هذا البحث خوارزمية للنمذجة والتحكم بمسألة ملاحقة مسار لمنصة تفرعية سداسية الأذرع من خلال النموذج التفاضلي العكسي بالاستعانة بالشبكات العصبونية، وذلك مع ضمان معالجة مشكلة عدم وثوقية النموذج وضمان التكيف مع التغيرات الحاصلة في أثناء العمل والاضطرابات الخارجية ضمن البيئة المحيطة تمّ تحديد قيم الأوزان البدائية للشبكة العصبونية باستخدام خوارزمية عناصر السرب الأمثلية، إضافة إلى تحديد هيكلية الشبكة العصبونية الأمثلية اللازمة لتقدير النموذج التفاضلي، وذلك بهدف الحصول على أفضل أداء للشبكة بأقل زمن تدريب ممكن. دربنا هذه الشبكة بالاعتماد على مجموعة بيانات تدريب شمولية غطت على كامل فضاء عمل المنصة، وذلك من دون الحاجة إلى معرفة التشكيلة الهندسية أو النموذج الرياضي للذراع الروبوتية استثمرت الشبكة المدربة ضمن حلقة التحكم لقيادة المنصة التفرعية في مسألة ملاحقة مسار مرجعي، حيث تم الاعتماد على البيانات المُحصلة في أثناء عمل المنصة لإعادة تدريب الشبكة العصبونية وذلك لمواكبة التغيرات الحاصلة ضمن الجملة أظهرت نتائج المحاكاة كفاءة الخوارزمية المُقترحة في مسألة ملاحقة المسار المرجعي والقدرة على تحسين الأداء ومواكبة التغيرات الحاصلة على جملة المنصة التفرعية. تمكن النموذج المُقترح من تخفيض خطأ الملاحقة بنسبة وسطية تصل إلى ٩٢,٢٪ وذلك مع افتراض وجود اختلاف بطول أحد أذرع المنصة، وكذلك بنسبة وسطية تصل إلى ٢٧,٣٪ مع افتراض وجود خلوصات ميكانيكية ضمن مفعلات المنصة، كما تميزت الخوارزمية المُقترحة بالصلادة ضد الضجيج والاضطرابات الخارجية

المقدمة

ازداد في الآونة الأخيرة استخدام المنصات التفرعية بوجه عام، ومنصة ستيرورات التفرعية بوجه خاص، ضمن التطبيقات الصناعية؛ وذلك نظراً لما تتمتع به، مقارنةً مع نظيراتها التسلسلية، من مزايا مهمة كالسلوك الديناميكي العالي وقدرة التحمل الكبيرة للحمولات والقوى الخارجية، إضافةً إلى الدقة العالية في تموضع جسمها الطرفي. تتألف المنصات التفرعية بوجه عام من قاعدتين؛ إحداهما ثابتة والأخرى متحركة، تتصلان ببعضهما عن طريق مجموعة من الأذرع. جرى اقتراح مجموعة من المنصات التفرعية بست أذرع وست درجات حرية، ومن أهم هذه المنصات هي المنصة التفرعية RSU-6 (الشكل (1)) التي تحوي ضمن كل ذراع من أذرعها الست الروابط التالية على التسلسل: رابطة دورانية (Revolute) ثم رابطة كروية (Spherical) وبعدها رابطة عمومية (Universal). من أهم مزايا هذه المنصة هي خفة وزن الجزء المتحرك منها نظراً لكون مفاصلها الستة ثابتة ضمن قاعدتها السفلية، ما يسمح بإمكانية استخدام مفاصل كهربائية كبيرة الحجم ورخيصة التكلفة. في المقابل، لهذه المنصة بعض السلبيات كالتعقيد الميكانيكي ومحدودية فضاء عملها، إضافة إلى التعقيد الرياضي الكبير في مسألة إيجاد نموذجها الرياضي.



الشكل (1): المنصة التفرعية المدروسة RSU-6.

تُعد مسألة النمذجة الروبوتية (الهندسية والحركية والديناميكية) أمراً بالغ الأهمية لدورها في عملية تصميم الأذرع الروبوتية ومحاكاتها والتحكم بها، ولكن في الوقت نفسه تعاني مسألة النمذجة هذه من التعقيد الرياضي الكبير والكلفة الحسابية والزمنية العالية، ولا سيما من أجل الأذرع الروبوتية التفرعية المعقدة. بوجه عام، تُحدّد هذه النماذج على نحو تحليلي بناءً على هندسية الذراع الروبوتية المدروسة، وذلك من خلال مجموعة من العلاقات الرياضية الناتجة عن حل جملة من المعادلات اللاخطية المعقدة. حديثاً، أثبتت الدراسات إمكانية الاستفادة من تقنيات التعلم الآلي والشبكات العصبونية في مسائل النمذجة والتحكم الآلي بالأذرع الروبوتية، إذ يمكن للشبكات العصبونية أن تحل محل النماذج الرياضية المعقدة لبعض الأنظمة الروبوتية [1] بالاستفادة من قابلية الشبكات العصبونية للتعلم من البيانات، ومن ثم إمكانية تحديد مجموعة العلاقات اللاخطية بين بيانات دخل وخرج النظام، ما يجعلها مرشحة بقوة لتقدير النماذج الرياضية للأنظمة الروبوتية [2]. تعتمد كفاءة طرق التحكم القائمة على النموذج على دقة هذه النماذج الرياضية وعلى دقة الحساسات المستخدمة ضمن حلقة التحكم، حيث نجد عملياً أن النموذج الرياضي للذراع الروبوتية يمكن أن يختلف عن النموذج الفعلي الناتج بعد عمليات التصنيع والتجميع، الذي يمكن أن يختلف لاحقاً في أثناء الاستثمار نتيجة للاحتكاك واهتزاز الروابط وظهور خلوصات ميكانيكية. ولذلك، بغية التغلب على هذه المشكلات، نهدف هنا إلى التحقق من إمكانية استخدام الشبكات العصبونية لنمذجة الأذرع الروبوتية التفرعية، إضافة إلى التحقق من إمكانية تعميم هذه الفكرة على نظام مع وجود اضطرابات

خارجية ومشكلات عدم الدقة في النموذج، ومن مقدرة الشبكات العصبونية على تقليل الأثر السلبي للخلوصات الميكانيكية التي من الممكن أن تظهر ضمن مفاصل الذراع الروبوتية. سابقاً، جرى اقتراح مجموعة من الطرق للنمذجة والتحكم بالأذرع الروبوتية بوجه عام والتفرعية منها بوجه خاص، إذ اقترح إطار للتعلم العميق deep learning framework للتحكم بحركة ذراع روبوتية من خلال النموذج الهندسي باستخدام الشبكات العصبونية العميقة والشبكات العودية LSTM [3]. في [4] اقترحت شبكة تفرعية تجمع بين الشبكات العصبونية ذات الأساس الشعاعي radial basis function والشبكات العصبونية التلافيفية convolutional neural networks للحصول على تعويض دقيق لديناميك الذراع الروبوتية بالاستعانة بالتحكم بالنمط المنزلق. إضافة إلى ذلك، اقترح البحث [5] شبكة عصبونية مزدوجة dual neural network للتحكم بحركة ذراع روبوتية من دون الاعتماد على النموذج، وذلك مع ضمان التقارب والاستقرار الشامل global stability. واقترح الباحثون في [6] شبكة عصبونية لتحديد النموذج الهندسي العكسي لذراع روبوتية تسلسلية، وذلك من خلال تضمين الموضع الحالي للنهاية الطرفية للذراع في النموذج العصبوني، وأظهرت النتائج تحسن دقة النموذج وتقليل نسبة الخطأ إلى أقل من النصف ضمن فضاء العمل الديكارتي. واقترح الباحثون في [7] شبكة عصبونية للتحكم بحركة ذراع تفرعية بالاعتماد على النموذج الهندسي العكسي ضمن الزمن الحقيقي، وذلك من خلال تضمين الموضع الحالي للنهاية الطرفية ولزوايا المفاصل ضمن النموذج العصبوني. أما في [8]، فقد اقترح متحكم تكيفي بالاستعانة بالشبكات العصبونية العودية recurrent neural networks لذراع روبوتية مع فائضية لمعالجة مشكلة عدم اليقين ضمن النموذج، حيث يلزم في هذه الطريقة معرفة النموذج الهندسي للذراع المدروسة. بينت النتائج عمل الخوارزمية بوجه جيد حتى مع وجود مشكلات عدم الوثوقية ضمن النموذج أو ضمن البيئة المحيطة. كذلك اقترح الباحثون في [9] شبكة عصبونية عودية للتحكم بحركة ذراع روبوتية، وتهدف الخوارزمية هنا إلى تقليل أثر الضجيج ضمن نظام التحكم. وفي [10]، جرى اقتراح التحكم بحركة ذراع روبوتية مستوية بدرجة حرية من خلال الدمج بين شبكتين عصبونيتين، تُدرَّب إحداهما على نحو مسبق offline، والأخرى في أثناء العمل online، لتشكلاً سوية وحدة التحكم العصبونية بحركة الذراع. اقترح الباحثون في [11] شبكة عصبونية لحل مشكلة النموذج الهندسي العكسي لذراع روبوتية بست درجات حرية، وذلك مع إجراء تحسين على خوارزمية الانتشار الخلفي اللازمة لتدريب الشبكة العصبونية. أظهرت نتائج المحاكاة كفاءة الطريقة المقترحة في تعزيز دقة النموذج والتخفيف من التعقيد الحسابي. كذلك في [12]، اقترحت منهجية قائمة على الشبكات العصبونية لحل مشكلة النموذج الهندسي العكسي لذراع روبوتية تسلسلية بست درجات حرية، وذلك بالدمج مع تقنية تقليل الأخطاء العددية numerical error minimization. يتم فيها تبسيط تعقيد النموذج العكسي من خلال إستراتيجية تسمى تجزئة فضاء العمل الربطي joint space segmentation، إذ يجري إنشاء مجموعة من الشبكات العصبونية متعددة الطبقات (MLP) من أجل الوصول إلى النموذج الهندسي العكسي على نحو مجزأ. اقترحت أيضاً في [13] شبكة عصبونية عميقة للتحكم بذراع تفرعية وذلك بالاعتماد على خوارزمية COVID-19-19 للعثور على الأوزان الأولية initial weights المتألية للشبكة العصبونية. نلاحظ أن معظم الأبحاث قد نُفذت بالاعتماد على النموذج الهندسي العصبوني للتحكم بالذراع الروبوتية، وذلك بهدف تحسين جودة التحكم بالاستعانة بالشبكات

المرفقي المُستخدم ضمن كل ذراع من أذرع المنصة الست (الشكل (٢)).

وفي المقابل، يُعرف النموذج التفاضلي المباشر بأنه جملة العلاقات التي تعبر عن التغيرات الجزئية الصغيرة لحركة الجسم الطرفي dX بدلالة التغيرات الجزئية الصغيرة للمتحولات المفصلية dq ، بالاستعانة بالمتصفوفة اليعقوبية وفق العلاقة التالية: . بالاستعاضة عن التغيرات الجزئية الصغيرة للمتحولات بمشتقات هذه المتحولات بالنسبة للزمن، يتم الحصول على النموذج الحركي، الذي يعطي مركبات سرعة الجسم الطرفي بدلالة سرع الإحداثيات المفصلية المزودة بمفصلات، وذلك وفق العلاقة التالية [١٥]:

$$J_q \dot{q} = J_x \dot{X} : \dot{X} = \begin{bmatrix} \dot{x}_1 \\ \dot{y}_1 \\ \dot{z}_1 \end{bmatrix}, \dot{q} = [\dot{\theta}_1, \dots, \dot{\theta}_6] \quad (2)$$

$$\Rightarrow \dot{X} = J \dot{q} : J = (J_x)^{-1} J_q$$

يجري تحديد هذا النموذج للميكانيزم ٦-RSU قيد الدراسة انطلاقاً من اشتقاق النموذج الهندسي العكسي، ومنه يجري الوصول إلى العلاقات التالية [١٥]:

$$J_x = \begin{bmatrix} \lambda_1^T & (c_1 \times \lambda_1)^T \\ \lambda_2^T & (c_2 \times \lambda_2)^T \\ \vdots & \vdots \\ \lambda_6^T & (c_6 \times \lambda_6)^T \end{bmatrix} : \lambda_i = (C_i - B_i) \quad (3)$$

$$J_q = \text{diag} [\lambda_{q1}, \lambda_{q2}, \dots, \lambda_{q6}] : \lambda_{qi} = \lambda_i^T R_i \begin{bmatrix} -l_i \sin(\theta_i) \\ l_i \cos(\theta_i) \\ 0 \end{bmatrix}$$

حيث تعبر النقاط A_i, B_i, C_i كذلك عن مراكز الروابط الدورانية فالكروية والعمومية، على التسلسل، كما تعبر R_i عن مصفوفة الدوران بين الجملة المرتبطة بالمفصل الدوراني للذراع i والجملة المرتبطة بالقاعدة الثابتة للمنصة. ونظراً لأن المصفوفة اليعقوبية في حالتنا هذه هي مصفوفة مربعة بأبعاد 6×6 فمن السهل تحديد حالاتها الشاذة وذلك من خلال إيجاد الوضعيات التي تؤدي لانعدام محدها . يتحقق ذلك عملياً عندما تكون إحدى المصفوفتين أو كلاهما شاذة.

المواد والطرائق

بوجه عام، يجري استخدام نوعين أساسيين من الشبكات العصبونية ضمن تطبيقات نمذجة الأذرع الروبوتية وهما: الشبكات العصبونية ذات الأساس الشعاعي (RFB) Radial Function Basis والشبكات العصبونية متعددة الطبقات Multilayer Perceptron (MLP). تُعطي الشبكات العصبونية ذات الأساس الشعاعي دقة أكبر في تمثيل النموذج، ولكنها تعاني كلفة حسابية عالية [١٦]، في المقابل تضمن الشبكات العصبونية متعددة الطبقات حلاً وسطياً يجمع بين الدقة والكلفة الحسابية المقبولة. بناءً عليه، وبالأخذ في الحسبان الحاجة إلى ضمان السرعة في إعادة تدريب بارامترات الشبكة في أثناء العمل، نعتمد ضمن هذا البحث استخدام الشبكات العصبونية متعددة الطبقات لتقدير النموذج التفاضلي المنشود.

تصميم النموذج التفاضلي العصبوني

في العديد من التطبيقات، تتحرك الذراع الروبوتية وفق مسار محدد مسبقاً على طول تسلسل معين من النقاط ضمن فضاء العمل. ضمن هذه التطبيقات تبين أن تضمين الموضع الحالي للنهاية الطرفية للذراع الروبوتية وكذلك قيم المفصلات الحالية في النموذج العصبوني له نتائج

العصبونية، في حين أننا نسعى في هذا البحث إلى الوصول إلى نموذج تفاضلي عصبوني لمنصة ستوارت التفرعية ذات المخدمات الدورانية، وذلك من دون الاعتماد على النماذج والعلاقات الرياضية، واستثماره لاحقاً ضمن نظام تحكم بملاحقة مسار مرجعي للمنصة، بحيث يمكن أن يتكيف مع التغيرات الحاصلة في أثناء العمل. لتحقيق هذا الهدف، بدأنا أولاً بنمذجة المنصة باستخدام الشبكات العصبونية، وبعد ذلك تُستثمر هذه الشبكة العصبونية في النظام كوحدة تحكم بغية الوصول إلى تتبع المسار المرجعي. يمكن تلخيص المساهمات ضمن هذا البحث بما يلي:

- تطوير النموذج التفاضلي لمنصة ستوارت التفرعية ذات المخدمات الدورانية بالاعتماد على الشبكات العصبونية.
- تحديد هيكلية الشبكة العصبونية وقيم أوزانها البدائية باستخدام خوارزمية عناصر السرب الأمثلية.
- تعديل معاملات النموذج العصبوني ضمن حلقة التحكم بالمنصة في أثناء العمل، وذلك مع افتراض وجود اختلاف بأطوال أذرع المنصة، أو حالة وجود خلوص ميكانيكي backlash ضمن مفصلاتها الدورانية. نعرض فيما يلي دراسة نظرية تتضمن التعريف بمنصة ستوارت التفرعية ٦-RSU وتحديد نموذجها الهندسي والحركي، وصولاً إلى تصميم النموذج العصبوني المنشود وتحديد بنيته الأمثلية. نعرض بعدها حلقة التحكم التي بُنيت لملاحقة مسار مرجعي للمنصة، ومن ثم النتائج العملية التي توضح أداء النموذج العصبوني وقدرته على التكيف مع التغيرات الحاصلة في أثناء العمل. نختم المقالة بخاتمة ومجموعة من الأفاق المستقبلية لهذا العمل.

الدراسة النظرية

يُعرف النموذج الهندسي المباشر بأنه جملة العلاقات التي تعبر عن وضع العنصر الطرفي X كتابع لقيم مفصلات الميكانيزم q ويُعرف بالعلاقة:

$$X = f(q)$$

حيث يعبر الشعاع $X = [p_x, p_y, p_z, \varphi, \theta, \psi]$ عن قيم موضع وتوجه مركز القاعدة العلوية للمنصة بالنسبة للجملة المرتبطة بمركز القاعدة السفلية، في حين يعبر الشعاع $q = [\theta_1, \theta_2, \dots, \theta_6]$ عن قيم زوايا المفصلات الدورانية الستة للمنصة. وفي المقابل، يُعرف النموذج الهندسي العكسي بالعلاقة: $q = f^{-1}(X)$.

بوجه عام، إن إيجاد النموذج الهندسي العكسي في حالة الأذرع التفرعية أسهل من إيجاد النموذج الهندسي المباشر، فإيجاد النموذج الهندسي العكسي يُبنى على علاقات هندسية بسيطة إلى حد ما مقارنة بالطرق المعقدة اللازمة لإيجاد النموذج الهندسي المباشر، الذي يعتمد بوجه عام على طرق رقمية وتكرارية نظراً للتعقيد الكبير للمعادلات والترابط فيما بينها وتعدد الحلول الممكنة [١٤]. في حالتنا، يجري تحديد النموذج الهندسي العكسي بطريقة هندسية وفق العلاقات التالية [١٥]

$$\theta_i = \text{atan2}(S_i, C_i) \quad (1)$$

$$\begin{cases} S_i = \sin \theta_i = \frac{P_i Y_O + X_O \sqrt{I_i}}{X_i^2 + Y_i^2} \\ C_i = \cos \theta_i = \frac{P_i X_O - Y_O \sqrt{I_i}}{X_i^2 + Y_i^2} \end{cases} : \begin{cases} \Gamma_i = X_i^2 + Y_i^2 - P_i \\ P_i = \frac{L_i^2 + C_i^2 - L_i^2}{2L_i}, L_i = |C_i| \end{cases}$$

حيث تعبر النقاط A_i, B_i, C_i عن مراكز الروابط الدورانية فالكروية والعمومية، على التسلسل، كما يعبر عن طولي الميكانيزم الساعدي

إعداد بيانات التدريب

لتحديد النموذج العصبي المنشود، يلزم توليد مجموعة بيانات تدريب عشوائية وشمولية على كامل فضاء عمل المنصة التفرعية واللازمة لتدريب النموذج. ضمن بيئة MatLab وبالإستعانة بمكتبة الـ Simscape Multibody Toolbox، قمنا بإستيراد التصميم الميكانيكي للمنصة التفرعية قيد الدراسة والمتوافق مع أبعاد منصة مخبرية حقيقية (أبعاد قاعدتي المنصة وأطوال أذرعها) والموضحة ضمن الجدول (1)، حيث تم ضمن بيئة المحاكاة بناء النموذج الديناميكي الخاص بالمنصة، وذلك كما هو موضح ضمن الشكل (5).

الجدول (1): قيم البارامترات الهندسية لمنصة ستيوارت RSU.6-						
البارمتر	d_{b1}	d_{b2}	d_{p1}	d_{p2}	l_1	l_2
القيمة (cm)	26	20	30	6	11	25.5

باستخدام بيئة المحاكاة السابقة، يجري توليد مجموعة نقاط تدريبية شمولية على كامل فضاء عمل هذه المنصة ذي درجات الحرية الست، والموصف بإمكانية حركة مركز الجسم الطرفي للمنصة (القاعدة المتحركة) ضمن مكعب بطول ضلع 10cm وفق المحاور الديكارتية $[x, y, z]$ ، وذلك مع إمكانية الدوران ضمن هذا المكعب بمجال زاوي $\pm 5^\circ$ حول المحاور الأساسية الثلاث $[\phi, \theta, \psi]$. يجري هنا توليد مجموعة بيانات التدريب اللازمة، وذلك من خلال ربط كل عينة من فضاء العمل $X_{[k]}$

مفيدة في تقدير قيمة زوايا المفعلات للانتقال إلى الموضع التالي المطلوب [7]، وهذا ما يكافئ تمثيل النموذج العصبي للنموذج التفاضلي العكسي للمنصة والذي يُعطي التغيرات الجزئية لحركة المفعلات بدلالة التغيرات الجزئية لحركة الجسم الطرفي وفق العلاقة التالية:

$$dq = J^{-1}(q)dx \quad (4)$$

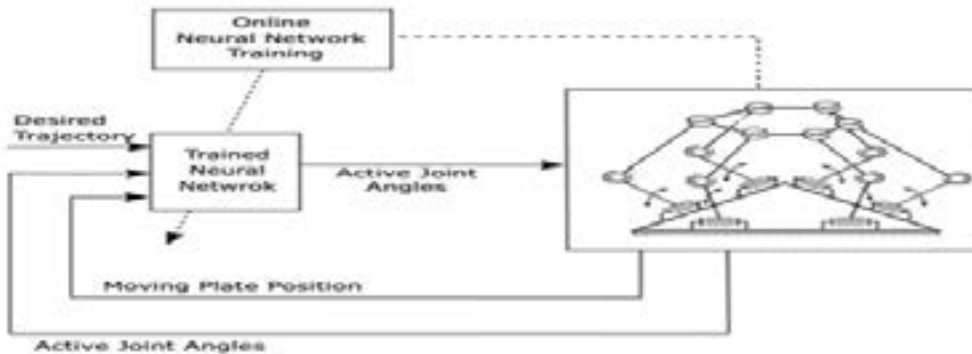
$$(q_{[k+1]} - q_{[k]}) = J^{-1}(q).(X_{[k+1]} - X_{[k]})$$

قمنا بتصميم النموذج العصبي المقترح ضمن الحلقة المغلقة، وذلك بالاستفادة من القيم الفعلية الراجعة ضمن حلقة التحكم، حيث يتكون دخل الشبكة من ثلاثة مداخل، وهي: قيمة الموضع المرغوب الانتقال إليه $X_{[k+1]}$ ، وقيمة الموضع

الحالي للجسم الطرفي للمنصة التفرعية $X_{[k]}$ ، وقيمة زوايا المفعلات الستة الحالية للمنصة $q_{[k]}$. أما خرج الشبكة فهو قيمة زوايا المفعلات الستة اللازمة للوصول إلى الموضع

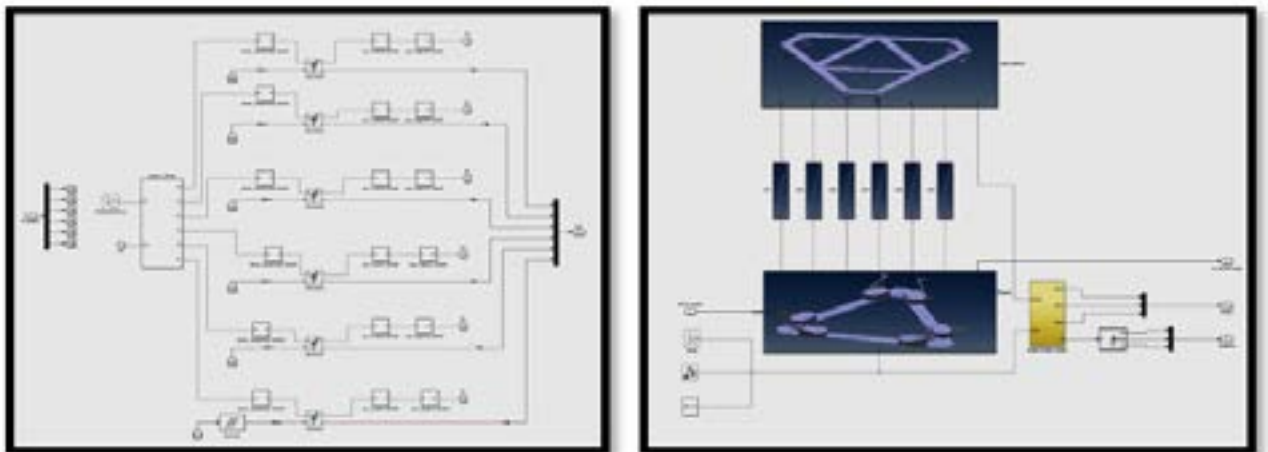
المرغوب $q_{[k+1]} = [\theta_1, \theta_2, \theta_3, \theta_4, \theta_5, \theta_6]$ ، بحيث يتنبأ النموذج العصبي المقترح بقيم زوايا المفعلات اللازم تطبيقها على المنصة التفرعية لنقل الجسم الطرفي إلى الوضعية المرغوبة

وفق العلاقة التالية: $\hat{q}_{[k+1]} = f(X_{[k+1]}, X_{[k]}, q_{[k]})$ ، حيث تُعبر k عن الخطوة الزمنية ضمن حلقة التحكم



الشكل (4): حلقة التحكم بالاستعانة بالنموذج التفاضلي العصبي ضمن الحلقة المغلقة.

بقيم المفعلات الدورانية الستة الموافقة $q_{[k]}$ وكذلك مع القيم باللحظات السابقة $q_{[k-1]}, X_{[k-1]}$. يلزم إجراء معالجة أولية لهذه البيانات لتجهزها لعملية التدريب، وذلك من خلال إجراء عملية تقييس normalization للعينات ضمن المجال $[-1, 1]$ ، مع حذف العينات المتشابهة constant rows أو الشاذة. كما يلزم أن تكون هذه البيانات شاملة وتغطي كامل فضاء العمل المدروس، فكلما ازداد حجم هذه البيانات ازدادت دقة نتائج النموذج العصبي، إلا أننا نصل بعد حد معين إلى مرحلة الإشباع، بحيث لا تؤدي عندها زيادة حجم بيانات التدريب إلى زيادة كفاءة النموذج، وإنما مع ازدياد حجم هذه العينات يزداد تعقيد عملية التدريب مع استهلاك زمن تدريب كبير.



الشكل (5): نمذجة المنصة التفرعية المدروسة ضمن بيئة Matlab.

أداء الشبكة وسرعة تقاربها، وذلك من خلال إيجاد القيمة الأصغر لـ Minimize لتابع الكلفة J الذي يجمع بين القيمة المُقيّسة لمتوسط الخطأ التربيعي mean squared error لخرج الشبكة العصبونية مقابل خرج البيانات الحقيقية، والقيمة المُقيّسة للزمن اللازم لتدريب الشبكة، كما هو موضح في المعادلة التالية:

$$J = \frac{1}{2}MSE_{(max-norm)} + \frac{1}{2}t_{training\ time_{(max-norm)}} \quad (5)$$

$$:MSE = \frac{1}{n} \sum_{i=1}^n (q[i] - \hat{q}[i])^2$$

حيث هي القيمة الحقيقية لزوايا المفعلات الستة، وهي خرج النموذج العصبوني.


الجدول (2): معاملات خوارزمية PSO.							
البارامتر	حجم السرب	نوع الترميز	إستراتيجية الاختيار عشوائي	نوع التداخل متفرق	وزن التكيف الذاتي (C2)	وزن التكيف الاجتماعي (C1)	العزم (W)
القيمة	10	حقيقي	Stochastic	Scattered	1.49	1.49	1.1

وخرج النظام، المتمثل بقيم المفعلات الدورانية الستة للمنصة العميق deep learning Toolbox، وذلك باستخدام خوارزمية الانتشار الخلفي Levenberg-Marquardt backpropagation، وهي من خوارزميات التدريب الأشهر للشبكات العصبونية والتي تضمن سرعة التقارب مع الوصول إلى دقة نموذج مقبولة. تم اعتماد حجم مجموعة التدريب ضمن مسألتنا المطروحة بـ 8000 عينة (دخل/خرج) شمولية على كامل فضاء عمل المنصة. عملياً، خلال التدريب، تنقسم مجموعة بيانات التدريب إلى ثلاث مجموعات رئيسية: مجموعة التدريب Training data وتضم 70% من حجم البيانات الكلي، مجموعة الاختبار Testing data وتضم 15% من حجم البيانات، ومجموعة التحقق Validation data وتضم أيضاً 15%، وتستخدم هذه الأخيرة لاختبار النموذج في أثناء مرحلة التدريب لتجنب مشكلات التعليم الزائد overfitting. بالاعتماد على خوارزمية عناصر السرب الأمثلية تم الوصول إلى هيكلية الشبكة العصبونية الأمثلية وفق مخطط تقارب الخوارزمية الموضحة ضمن الشكل (6)، والتي تتكون من:

$$\hat{q}_{[k+1]} = f(X_{[k+1]}) \quad (6)$$

يوضح الشكل (7) حلقة التحكم بالاستعانة بالنموذج الهندسي العصبوني ضمن الحلقة المفتوحة. وبالاعتماد أيضاً على خوارزمية عناصر السرب الأمثلية جرى الوصول إلى هيكلية الشبكة العصبونية التالية والتي تضمن كذلك أفضل أداء بأقل زمن تدريب ممكن:

- طبقة الدخل: تتألف من 6 عصبونات، بما يتوافق مع شعاع دخل الشبكة.
- ثلاث طبقات مخفية، تتألف كل منها من 10 و 11 و 10 خلية عصبية (عصبون) على التوالي، وباستخدام توابع تفعيل Sigmoid.
- طبقة الخرج بستة عصبونات خطية Linear، بما يتوافق مع خرج الشبكة.



الشكل (7): حلقة التحكم بالاستعانة بالنموذج الهندسي العصبوني ضمن الحلقة المفتوحة.

بعد تحديد مداخل ومخارج النموذج العصبوني، يلزم تحديد بنية وهيكلية الشبكة العصبونية من حيث عدد الطبقات المخفية وعدد العصبونات في كل طبقة منها، إضافة إلى نوع توابع التفعيل لهذه العصبونات. نهدف هنا إلى الوصول إلى هيكلية الشبكة العصبونية الأمثلية، بحيث نصل إلى أفضل دقة بتمثيل النموذج وبأقل زمن تدريب ممكن. بوجه عام، يجري استخدام نوعين أساسيين من خوارزميات البحث الأمثلي ضمن تطبيقات النمذجة للأذرع الروبوتية وهما: الخوارزمية الجينية Genetic Algorithm وخوارزمية عناصر السرب الأمثلية Particle Swarm Optimization. بالمقارنة بين أداء الخوارزمتين، كان التفوق لخوارزمية عناصر السرب الأمثلية [17, 18]، إذ تضمن هذه الخوارزمية التقارب نحو حل أمثلي أفضل، وذلك خلال زمن تنفيذ أقل مقارنة بالخوارزمية الجينية. بناءً عليه، استخدمنا خوارزمية عناصر السرب الأمثلية وفق المعاملات الموضحة ضمن الجدول (2)، وذلك بغية الوصول إلى هيكلية الشبكة العصبونية الأمثل، إضافة إلى تحديد قيم أوزانها المبدئية الأمثلية، التي تؤثر تأثيراً مباشراً في

تدريب الشبكة العصبونية ضمن بيئة Matlab باستخدام أدوات التعلم العميق deep learning Toolbox، وذلك باستخدام خوارزمية الانتشار الخلفي Levenberg-Marquardt backpropagation، وهي من خوارزميات التدريب الأشهر للشبكات العصبونية والتي تضمن سرعة التقارب مع الوصول إلى دقة نموذج مقبولة. تم اعتماد حجم مجموعة التدريب ضمن مسألتنا المطروحة بـ 8000 عينة (دخل/خرج) شمولية على كامل فضاء عمل المنصة. عملياً، خلال التدريب، تنقسم مجموعة بيانات التدريب إلى ثلاث مجموعات رئيسية: مجموعة التدريب Training data وتضم 70% من حجم البيانات الكلي، مجموعة الاختبار Testing data وتضم 15% من حجم البيانات، ومجموعة التحقق Validation data وتضم أيضاً 15%، وتستخدم هذه الأخيرة لاختبار النموذج في أثناء مرحلة التدريب لتجنب مشكلات التعليم الزائد overfitting. بالاعتماد على خوارزمية عناصر السرب الأمثلية تم الوصول إلى هيكلية الشبكة العصبونية الأمثلية وفق مخطط تقارب الخوارزمية الموضحة ضمن الشكل (6)، والتي تتكون من:


- طبقة الدخل: تتألف من 18 عصبوناً، بما يتوافق مع المداخل الثلاثة للشبكة.
- ثلاث طبقات مخفية، تتألف كل منها من 16 و 40 و 30 خلية عصبية (عصبوناً) على التوالي، وباستخدام توابع تفعيل من نوع Sigmoid.
- طبقة الخرج بستة عصبونات خطية Linear، بما يتوافق مع خرج الشبكة.

أعطت هذه الشبكة متوسط الخطأ التربيعي 0.1007، وكان الوقت اللازم للتدريب هو: 1,0497 ثانية. (وذلك باستخدام حاسب بالموصفات التالية: Intel Core i5 (3,0GHz) - (16,0GB)RAM).

تصميم النموذج الهندسي العصبوني: لتوضيح أهمية النموذج التفاضلي العصبوني المقترح، نطرح هنا دراسة مقارنة بينه وبين النموذج العصبوني التقليدي القائم على النموذج الهندسي العكسي، الذي يربط بوجه مباشر بين

دخل النظام، المتمثل بقيم موضع وتوجه الجسم الطرفي $X_{[k+1]}$

أثناء العمل لإعادة تدريب النموذج العصبي، وذلك لمواكبة التغيرات الحاصلة ضمن الجملة. يوضح الشكل (٨) مخطط خوارزمية التحكم بملاحقة المسار لمنصة ستوارت القرعية باستخدام النموذج العصبي المقترح، ويتألف المخطط بوجه أساسي من: كتلة الشبكة العصبونية المُدرّبة مسبقاً، كتلة إعادة تدريب الشبكة العصبونية في أثناء العمل، وكتلة المنصة القرعية المدروسة مع مفاعلاتها الدورانية.



الشكل (٨): حلقة التحكم ضمن بيئة Matlab بالاستعانة بالنموذج التفاضلي العصبي ضمن الحلقة المغلقة.

العصبونية في أثناء العمل (online)، وأهم ميزات هذه الخوارزمية المقترحة هي سرعة الأداء في عملية إعادة التدريب. عملياً، أعيد تدريب النموذج العصبي المقترح من أجل كل ١٠٠٠ عينة تدريب جديدة، إذ يمكن في نهاية المسار المرجعي تجهيز مجموعة بيانات التدريب الجديدة المحصلة في أثناء تنفيذ المسار، ودمجها في مجموعة بيانات التدريب الأساسية، ومن ثم استخدامها لإعادة تدريب النموذج العصبي، ونصل بالنتيجة إلى النموذج العصبي المعدل والمتكيف مع التغيرات الحاصلة على جملة المنصة.

النتائج:

نعرض هنا نتائج محاكاة الخوارزمية المقترحة ضمن بيئة MatLab باستخدام مكتبة الـ Simscape Multibody Toolbox. ولاختيار الخوارزمية المقترحة، نعتمد على ملاحقة مسارين مرجعيين: مسار دائري حلزوني بشكل انسيابي ضمن الفضاء الانسحابي، وكذلك مسار دائري حلزوني بشكل انسيابي ضمن الفضاء الدوراني والمعرفة بالمعادلات التالية:

$$\begin{cases} x = 4 \sin(t) \text{ (cm)} \\ y = 4 \cos(t) \text{ (cm)} \\ z = 19 + 8 \left(\frac{t}{2\pi}\right) \text{ (cm)} \end{cases} \quad \begin{cases} \text{Phi} = -2 + 4 \left(\frac{t}{2\pi}\right) \text{ (deg)} \\ \text{Theta} = -2 \sin(t) \text{ (deg)} \\ \text{Xai} = -2 \cos(t) \text{ (deg)} \end{cases} \quad t \in [0, 2\pi] \quad (7)$$

يجري تقييم دقة وحدة التحكم عن طريق حساب خطأ المسافة الإقليدية من أجل درجات الحرية الست للمنصة (خطأ الانسحابات وخطأ الدورانات)، وذلك كما هو موضح في المعادلة التالية

$$\begin{aligned} e_{\text{Transition}} &= \sqrt{e_x^2 + e_y^2 + e_z^2} \\ e_{\text{Rotation}} &= \sqrt{e_{\text{Phi}}^2 + e_{\text{Theta}}^2 + e_{\text{Xai}}^2} \end{aligned} \quad (8)$$

لدراسة أداء النموذج العصبي نفترض إمكانية حصول التغييرات التالية:

- وجود اختلاف في الأبعاد الهندسية الحاكمة للمنصة (اختلاف طول ذراع المنصة)، وذلك نتيجة للاختلاف الحاصل فرضاً بين قيمتها النظرية وقيمتها العملية بعد التصنيع والتجميع الميكانيكي.

بناء خوارزمية التحكم

ضمن خوارزمية التحكم المُعتمدة، يتم بدايةً تدريب الشبكة العصبونية على نحو مسبق (offline) بالاعتماد على مجموعة بيانات التدريب الشمولية (٨٠٠٠ عينة) المُحصلة مسبقاً من فضاء عمل المنصة، ومن ثم تستخدم هذه الشبكة ضمن حلقة التحكم لقيادة المنصة القرعية في مسألة ملاحقة المسار المرجعي المطلوب. وفي أثناء عمل المنصة، يجري الاعتماد على البيانات الجديدة المُحصلة في

في أثناء عمل المنصة وفي كل لحظة زمنية، يجري تحصيل عينات (دخل/خرج) للموضع الحقيقي للجسم الطرفي للمنصة مع قيم زوايا المفاعلات الحقيقية الموافقة. في كتلة إعادة تدريب الشبكة العصبونية، يجري تجميع عينات التدريب الجديدة ذات القيم المختلفة عن قيم مجموعة بيانات التدريب الأولية. عملياً، إن إضافة المزيد من عينات التدريب ستسبب زيادةً في حجم مجموعة التدريب، وهذا سيؤدي بالضرورة إلى زيادة وقت التدريب اللازم للشبكة العصبونية، لذلك يلزم عند إضافة عينة تدريب جديدة أن تُحذف عينة قديمة من مجموعة التدريب للحفاظ على ثبات حجمها. ويمكن أيضاً أن تؤدي عمليات الإضافة والحذف لعينات تدريب جديدة إلى الوصول إلى مجموعة تدريب منحازة وغير شمولية على كامل فضاء العمل. لحل هذه المشكلة نقترح تقسيم فضاء عمل المنصة القرعية المدروسة إلى مجموعة قطاعات مختلفة وذلك حسب موضع الجسم الطرفي للمنصة، عملياً تم تقسيم فضاء العمل إلى ٦٤ قطاعاً؛ إذ جرى تقسيم فضاء العمل الانسحابي بدايةً إلى ٨ قطاعات (من خلال المستويات الأساسية الثلاثة للفضاء الديكارتي X,Y,Z المارة من مركز القاعدة السفلية للمنصة)، ومن ثم جرى تقسيم كل قطاع منها إلى ٨ قطاعات إضافية لتشمل فضاء العمل الدوراني (كذلك من خلال المستويات الأساسية الثلاثة للفضاء الدوراني المارة من المركز)، وعلى هذا النحو فقد وصلنا إلى ٦٤ قطاعاً مختلفاً ضمن كامل فضاء العمل. ننوه هنا إلى أن زيادة عدد قطاعات فضاء العمل زيادة كبيرة ستؤدي إلى تعقيد المسألة وزيادة الوقت اللازم لمعالجة البيانات.

ضمن كتلة إعادة تدريب الشبكة العصبونية، ومن أجل عينة تدريب جديدة يتم تحصيلها، تُضاف هذه العينة إلى القطاع الذي تنتمي إليه من القطاعات الـ ٦٤ وذلك بناءً على موضع الجسم الطرفي لتلك العينة، وفي الوقت نفسه يجري حذف عينة قديمة عشوائياً من القطاع ذاته، وبذلك نضمن الحفاظ على مجموعة تدريب بعينات جديدة وبحجم ثابت (٨٠٠٠ عينة) وشاملة على كامل فضاء العمل. في كتلة إعادة تدريب الشبكة العصبونية، وبعد جمع مجموعة عينات تدريب جديدة، سيعاد تدريب الشبكة العصبونية الأساسية باستخدام مجموعة التدريب الجديدة، وبناءً عليه سَتُحدَّث مجموعة أوزان الشبكة العصبونية ضمن كتلة النموذج العصبي. لتسريع عملية إعادة تدريب الشبكة العصبونية، سيجري الاعتماد على الأوزان السابقة للشبكة كأوزان مبدئية، ومن ثم ستتقارب الشبكة العصبونية بصورة أسرع، ما يجعل خوارزمية إعادة التدريب خوارزمية عملية وفعالة في أثناء العمل. استخدم [١٩] هذه الخوارزمية لتحديث أوزان الشبكة

الملاحقة الانسحابي بنسبة ٥٩,٥% وكذلك خطأ الملاحقة الدوراني بنسبة ٧٢,٢%. من الممكن ملاحظة وجود ضعف في تحسين دقة الملاحقة ضمن بعض المناطق، ويعود ذلك لعدم تدريب النموذج العصبي بوجه جيد ضمن تلك المناطق.

مقارنة أداء النموذج التفاضلي العصبي

بداية نوضح الفرق الأساسي بين النموذج التفاضلي العصبي (المقترح) والنموذج الهندسي العصبي (التقليدي) على النحو الآتي:

- يربط النموذج الهندسي العصبي بين دخل النظام، المتمثل بقيم موضع وتوجه الجسم الطرفي المرغوب الانتقال إليه ، وخرج النظام، المتمثل بقيم المفاعلات الدورانية الستة للمنصة ، بحيث يتنبأ النموذج الهندسي العصبي بقيم زوايا المفاعلات الستة اللازم تطبيقها على المنصة التفرعية لنقل الجسم الطرفي إلى الوضعية المرغوبة.

- بينما يربط النموذج التفاضلي العصبي بين دخل النظام، المتمثل بقيم موضع وتوجه الجسم الطرفي المرغوب الانتقال إليه ، إضافة إلى قيم موضع وتوجه الجسم الطرفي الحالية للجسم الطرفي ، وكذلك قيم زوايا المفاعلات الستة الحالية للمنصة التفرعية ، وخرج النظام، المتمثل بقيم المفاعلات الدورانية الستة اللازمة للوصول إلى الوضعية المرغوبة. وبذلك يتنبأ النموذج التفاضلي العصبي بقيم زوايا المفاعلات الستة اللازم تطبيقها على المنصة التفرعية من خلال التغيرات الجزئية لحركة الجسم الطرفي، وذلك بالاستفادة من القيم الفعلية الراجعة ضمن حلقة التحكم.

نطرح هنا مقارنة بين أداء النموذج التفاضلي العصبي المقترح من أجل الحالات المدروسة السابقة، حيث نميز بين حالتين للتغيرات المفروضة:

- تغيرات ثابتة مع الزمن: كوجود اختلاف ضمن الأبعاد الهندسية للمنصة المدروسة.
 - تغيرات عشوائية غير ثابتة مع الزمن: كوجود خلوص ميكانيكي ضمن مفاعلات المنصة أو وجود ضجيج خارجي.
- بالنسبة للتغيرات الثابتة، تمكن النموذج التفاضلي العصبي المقترح من التكيف مع هذه التغيرات وإلغاء أثرها بوجه كامل بنسبة وسطية تصل إلى ٩٢,٢% من خلال خوارزمية إعادة التدريب المعتمدة، وذلك بخلاف النموذج العصبي التقليدي الذي لم يتمكن من إلغاء أثر هذه التغيرات سوى بنسبة ١٧,٧%. أما بالنسبة للتغيرات غير الثابتة مع الزمن، فقد تمكن النموذج التفاضلي المقترح من التكيف مع هذه التغيرات والتخفيف من أثرها بنسبة وسطية تصل إلى ٢٧,٣% من أجل حالة الخلوص الميكانيكي، ونسبة وسطية تبلغ ٦٥,٨% في حالة وجود الضجيج الخارجي. نفسر ذلك بأن وجود هذا النوع من التغيرات العشوائية سيؤدي بالضرورة إلى خلل في أداء عمل المنصة في ملاحقة المسار المرجعي، والذي لا يمكن السيطرة عليه تحكماً بوجه كامل، وإنما يجري التكيف معه والتخفيف من أثره.

- وجود خلوص ميكانيكي ضمن مفاعلات المنصة الستة بمقدار ٢deg، إذ يتم ذلك ضمن بيئة المحاكاة باستخدام وحدة الخلوص لميكانيكي backlash block الخاصة بذلك.
- وجود ضجيج أبيض خارجي ضمن خرج حساسات التحصيل لحلقة التحكم.

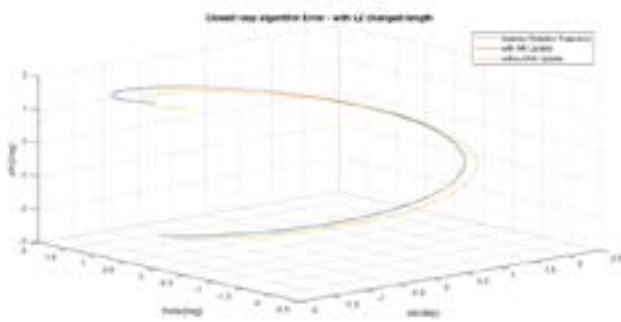
نعرض هنا نتائج كل من النموذجين العصبيين (التفاضلي والهندسي) في مسألة ملاحقة المسار المرجعي. وبغية تقييم أداء النموذج العصبي لمنصة ستوارت التفرعية، يُستخدَم هنا النموذج المُدرَّب مسبقاً ضمن حلقة التحكم بملاحقة المسار المرجعي، ونقارن هنا الأداء من أجل حالتين: مع تحديث أوزان النموذج العصبي في أثناء العمل أو من دون تحديث.

أداء النموذج التفاضلي العصبي مع وجود اختلاف في الأبعاد الهندسية للمنصة التفرعية


بدايةً نعرض نتائج النموذج التفاضلي المقترح مع افتراض وجود اختلاف في طول الذراع غير الفعال ضمن المنصة بقيمة . يوضح الشكل (٩) نتائج ملاحقة المسار المرجعي الحلزوني ضمن الحلقة المغلقة وذلك من أجل الإحداثيات الديكارتية (a)، ومن أجل الإحداثيات الدورانية (b). يوضح الشكل (١٠) نتائج خطأ ملاحقة المسار المرجعي الحلزوني ضمن الحلقة المغلقة وفق الإحداثيات الستة للمنصة التفرعية، وذلك من أجل تطبيق النموذج التفاضلي العصبي في حالتين: مع تحديث أوزانه خلال العمل أو من دون ذلك. كذلك يوضح الجدول (٣) مقارنة بين قيم خطأ الملاحقة خلال عملية ملاحقة المسار المرجعي الحلزوني مع وجود اختلاف بطول الذراع، وذلك من أجل الحالتين: مع تحديث أوزان النموذج خلال العمل أو من دون ذلك. نلاحظ من الشكلين (٩،١٠)، وبالمقارنة بين أداء النموذج العصبي مع وجود عملية إعادة تدريب للنموذج أو من دونها، وجود تحسن ممتاز بأداء الملاحقة، إذ جرى تقليل قيمة خطأ الملاحقة الانسحابي بنسبة ٩٣,٦% وكذلك خطأ الملاحقة الدوراني بنسبة ٩٠,٩%. تمكن النموذج المقترح هنا من التكيف مع التغيرات الحاصلة على جملة المنصة، وإلغاء تأثير التغير المفروض (تغير طول الذراع) بوجه كامل، والوصول إلى دقة أداء عالية تكافئ دقة الملاحقة بدون وجود أي تغيرات خارجية.

أداء النموذج الهندسي العصبي مع وجود اختلاف في الأبعاد الهندسية للمنصة التفرعية

في المقابل، نعرض هنا نتائج النموذج التقليدي مع افتراض وجود الاختلاف نفسه في طول الذراع غير الفعال ضمن المنصة، والموضحة ضمن الجدول (٤). نلاحظ هنا من الشكل (٤)، وبالمقارنة بين أداء النموذج العصبي مع وجود عملية إعادة تدريب للنموذج أو من دونها، قدرة النموذج المقترح على التكيف مع الضجيج الخارجي وتخفيف أثره، ومن ثم تحسين دقة الملاحقة، فقد تم تقليل قيمة خطأ




(b)



(a)


الشكل (٩): نتائج ملاحقة النموذج التفاضلي العصبي للمسار الحلزوني مع وجود اختلاف بطول الذراع وفق الإحداثيات الانسحابية (a) والدورانية (b).



الشكل (١٠): نتائج خطأ الملاحقة للنموذج التفاضلي العصبوني مع وجود اختلاف بطول الذراع وفق الإحداثيات الست للمنصة


الجدول (3): مقارنة بين قيم خطأ الملاحقة للنموذج التفاضلي العصبوني مع وجود اختلاف بطول الذراع.

<i>With L2 changed</i>	e_x (mm)	e_y (mm)	e_z (mm)	e_{phi} (deg)	e_{theta} (deg)	e_{xai} (deg)	$e_{transition}$ (mm)	$e_{rotation}$ (deg)
Without NN Update	0.53	0.92	1.15	0.11	0.12	0.15	1.57	0.22
With NN Update	0.06	0.07	0.06	0.006	0.006	0.017	0.10	0.02



الشكل (١١): نتائج خطأ الملاحقة للنموذج العصبوني التقليدي مع وجود اختلاف بطول الذراع وفق الإحداثيات الست للمنصة


الجدول (4): مقارنة بين قيم خطأ الملاحقة للنموذج العصبوني التقليدي مع وجود اختلاف بطول الذراع.



(b)

(a)


الشكل (١٢): نتائج ملاحقة النموذج التفاضلي العصبوني للمسار الحلزوني مع وجود خلوص ميكانيكي وفق الإحداثيات الانسحابية (a) والدورانية (b).



الشكل (١٣): نتائج خطأ الملاحقة للنموذج التفاضلي العصبوني مع وجود خلوص ميكانيكي وفق الإحداثيات الست للمنصة

الجدول (5): مقارنة بين قيم خطأ الملاحقة للنموذج التفاضلي العصبوني مع وجود خلوص ميكانيكي.

<i>With backlash</i>	e_x (mm)	e_y (mm)	e_z (mm)	e_{ϕ} (deg)	e_{θ} (deg)	e_{xai} (deg)	$e_{transition}$ (mm)	$e_{rotation}$ (deg)
Without NN Update	2.01	1.88	2.27	0.21	0.22	0.31	3.56	0.43



الشكل (١٤): نتائج خطأ الملاحقة للنموذج التفاضلي العصبوني مع وجود ضجيج خارجي وفق الإحداثيات الست للمنصة

الجدول (6): مقارنة بين قيم خطأ الملاحقة للنموذج التفاضلي العصبوني مع وجود ضجيج خارجي.

<i>With Noise</i>	e_x (mm)	e_y (mm)	e_z (mm)	e_{ϕ} (deg)	e_{θ} (deg)	e_{xai} (deg)	$e_{transition}$ (mm)	$e_{rotation}$ (deg)
Without NN Update	1.08	3.09	1.04	0.37	0.25	0.29	3.43	0.54
With NN Update	0.85	0.82	0.73	0.08	0.09	0.09	1.39	0.15

المغلقة والاعتماد على بيانات التدريب العودية القادمة من المنصة، وكذلك القدرة على التعلم السريع من بيانات التدريب الجديدة خلال خوارزمية إعادة التدريب، ومن ثم إمكانية تحسين أداء الملاحقة المنشود. إضافة إلى ذلك، تتميز الخوارزمية المقترحة بالصلادة ضد الضجيج والاضطرابات الخارجية، فقد تمكن النموذج المقترح من تخفيض خطأ الملاحقة بنسبة وسطية تصل إلى ٦٥,٨٪ وذلك من أجل حالة وجود ضجيج خارجي مفروض ضمن حساسات التحصيل لحظة التحكم. توضح هذه النتائج فاعلية استخدام الشبكات العصبونية كأداة قيمة في تعزيز أداء الملاحقة لمنصة ستوريت التفرعية، وتؤكد على أهمية النموذج المقترح وقابليته للتعميم على الأذرع الروبوتية التفرعية الأخرى. نسعى مستقبلاً إلى تطبيق الخوارزمية المقترحة باستخدام منصة تفرعية مخبرية قيد التطوير والتحقق من كفاءتها بوجه عملي.

الاستنتاجات والتوصيات

يطرح هذه البحث خوارزمية للنمذجة والتحكم بمسألة ملاحقة مسار لمنصة روبوتية تفرعية بالاعتماد على الشبكات العصبونية، وذلك مع ضمان معالجة مشكلة عدم وثوقية النموذج وضمان التكيف مع التغيرات الحاصلة في أثناء العمل والاضطرابات الخارجية ضمن البيئة المحيطة. تم الاعتماد على خوارزمية عناصر السرب الأمثلية للوصول إلى هيكلية الشبكة العصبونية المطلوبة. أظهرت النتائج تفوق النموذج التفاضلي العصبوني المقترح على النموذج العصبوني التقليدي، وقدرته على تحسين أداء الملاحقة والقدرة على مواكبة التغيرات الحاصلة على جملة المنصة. تمكن النموذج المقترح من إلغاء خطأ الملاحقة بنسبة وسطية تصل إلى ٩٢,٢٪ وذلك من أجل حالة وجود اختلاف بطول أحد أذرع المنصة، وكذلك تمكن من تخفيض خطأ الملاحقة بنسبة وسطية تصل إلى ٢٧,٣٪ وذلك من أجل حالة وجود خلوص ميكانيكي ضمن مفعلات المنصة الستة. تأتي أهمية النموذج التفاضلي المقترح باعتماده على إستراتيجية الحلقة

18. Joumah AA, Albitar C. Design optimization of 6-RUS parallel manipulator using hybrid algorithm. *Int. J. Inf. Technol. Comput. Sci.(IJITCS)*. 95-83:(2)10;2018.
19. Toshani H, Farrokhi M. Real-time inverse kinematics of redundant manipulators using neural networks and quadratic programming: a Lyapunov-based approach. *Robotics and Autonomous Systems*. 2014 Jun 81-766:(6)62;1.

التمويل: المعهد العالي للعلوم التطبيقية والتكنولوجيا.

مساهمات المؤلفين:

- الإطار المفاهيمي: م. علاء الدين جمعة، د. شادي بيطار، د. آصف جعفر
 - المنهجية: م. علاء الدين جمعة، د. شادي بيطار، د. آصف جعفر
 - التحقيقات: م. علاء الدين جمعة، د. شادي بيطار، د. آصف جعفر
 - إدارة المشروع: د. شادي بيطار، د. آصف جعفر
 - الإشراف: د. شادي بيطار، د. آصف جعفر
 - الكتابة - المسودة الأصلية: م. علاء الدين جمعة
 - الكتابة - المراجعة والتحرير: د. شادي بيطار، د. آصف جعفر.
- تضارب المصالح: "يعلن المؤلفون أنه ليس لديهم أي مصالح متضاربة".
- توافر البيانات والمواد: "البيانات متوفرة حين الطلب".

1. Jiang Y, Yang C, Na J, Li G, Li Y, Zhong J. A brief review of neural networks based learning and control and their applications for robots. *Complexity*. 2017 Oct 2017;31.
2. Toquica JS, Oliveira PS, Souza WS, Motta JM, Borges DL. An analytical and a Deep Learning model for solving the inverse kinematic problem of an industrial parallel robot. *Computers & Industrial Engineering*. 2021 Jan 151:106682;1.
3. Vaishnavi J, Singh B, Vijayvargiya A, Kumar R. Deep Learning Framework for Inverse Kinematics Mapping for a 5 DoF Robotic Manipulator. In *2022 IEEE International Conference on Power Electronics, Drives and Energy Systems (PEDES) 2022 Dec 14 (pp. 6-1)*. IEEE.
4. Wu H, Zhang X, Song L, Zhang Y, Wang C, Zhao X, Gu L. Parallel Network-Based Sliding Mode Tracking Control for Robotic Manipulators with Uncertain Dynamics. In *Actuators 2023 Apr 27 (Vol. 12, No. 5, p. 187)*. MDPI.
5. Li S, Shao Z, Guan Y. A dynamic neural network approach for efficient control of manipulators. *IEEE Transactions on Systems, Man, and Cybernetics: Systems*. 2017 Apr 41-932:(5)49;19.
6. Almusawi AR, Dülger LC, Kapucu S. A new artificial neural network approach in solving inverse kinematics of robotic arm (denso vp6242). *Computational intelligence and neuroscience*. 2016.
7. 19 Gholami A, Homayouni T, Ehsani R, Sun JQ. Inverse kinematic control of a delta robot using neural networks in real-time. *Robotics*. 2021 Oct 115:(4)10;16.
8. Zhou X, Xu Z, Li S, Wu H, Cheng T, Lv X, Zhou X, Xu Z, Li S, Wu H, Cheng T. RNN based adaptive compliance control for robots with model uncertainties. *AI Based Robot Safe Learning and Control*. 61-2020:39.
9. Li S, Wang H, Rafique MU. A novel recurrent neural network for manipulator control with improved noise tolerance. *IEEE transactions on neural networks and learning systems*. 2017 Apr 18-1908:(5)29;11.
10. ZHEKOV Z. Inverse Kinematics Neural Approximation and Neural Control of Two-link Planar Robot. In *2020 International Conference Automatics and Informatics (ICAI) 2020 Oct 1*. IEEE.
11. Gao R. Inverse kinematics solution of Robotics based on neural network algorithms. *Journal of Ambient Intelligence and Humanized Computing*. 2020 Dec;209-6199:(12)11.
12. Lu J, Zou T, Jiang X. A neural network based approach to inverse kinematics problem for general six-axis robots. *Sensors*. 2022 Nov 8909:(22)22;18.
13. Shamseldin, M. Real-time inverse dynamic deep neural network tracking control for Delta robot based on a COVID-19 optimization. *J. Robot. Control -643 ,4 ,2023 649*.
14. Merlet JP. *Parallel robots*. Springer Science & Business Media; 2006 Jul 1.
15. Bonev IA. *Geometric analysis of parallel mechanisms*. Canada: Université Laval; 2002 Nov.
16. Zubizarreta A, Larrea M, Irigoyen E, Cabanes I, Portillo E. Real time direct kinematic problem computation of the 3PRS robot using neural networks. *Neurocomputing*. 2018 Jan 14-271:104;3.
17. Xu Q, Li Y. Error analysis and optimal design of a class of translational parallel kinematic machine using particle swarm optimization. *Robotica*. 2009 Jan;78-67:(1)27.

