استخدام التعليم العميق في تدريب روبوت استقبال على كشف قناع الوجه للحد من انتشار فايروس كورونا

* أم.د.م. علي أحمد عجيب
** م. ربيع محمود السوقي
*** م. ديانا حسين الحسن

الملخص

يعتبر الذكاء الصنعي من أكثر المجالات التي جذبت انتباه الباحثين في هذا العصر، نظراً لأهميته في تقليد العقل البشري في حل المسائل المعقدة، كما تعتبر تطبيقات الذكاء الصنعي في الروبوتات مهمة جداً في تطوير أدائها.

تم في هذا البحث تقديم دراسة حول تصميم وتنفيذ نظام لتعليم الروبوت باستخدام الذكاء الصنعي، كما نفذت الدراسة على الروبوت (HBE-RoboCAR) مع إضافة تعديلات مقترحة للروبوت لجعله يتعلم وفق خوارزميات الذكاء الصنعي شملت الدراسة مكونات الروبوت التفصيلية وإضافة Raspberry PI الذي يمثل العقل القادر على معالجة خوارزميات الذكاء الصنعي (التعليم العميق)، نفذت خوارزمية الذكاء الصنعي بالاعتماد على شبكه التعليم العميق (CNN) لتميز الأشخاص الذين يرتدون قناع, وتم الاعتماد على مصنف (HAAR cascade) لتحديد الوجوه, حيث تم تنفيذ برنامج لتمييز الأشخاص الذين يرتدون قناع عن الأشخاص الذين لا يرتدونه، فكان الروبوت بمثابة مستقبل للزوار. أجريت مجموعة من التجارب على الروبوت المقترح، حيث تم استخدام 60% من قاعدة بيانات عالمية في مرحلة التدريب (بناء النموذج)، وتم الحصول على دقة 90% للتدريب.

كلمات مفتاحية: الذكاء الصنعي، التعليم العميق، Raspberry PI, الروبوت (HBE –RoboCAR).

---

*أستاذ مساعد دكتور في كلية الهندسة المعلوماتية في أكاديمية الأسد للهندسة العسكرية.

** مهندس في كلية الهندسة المعلوماتية في أكاديمية الأسد للهندسة العسكرية.

***مهندس معيد في كلية الهندسة المعلوماتية في أكاديمية الأسد للهندسة العسكرية.

Using deep learning to train a reception robot to detect a face mask to limit the spread of the Corona virus

***Ali Ahmed Ajeeb**
****Rabee Mahmoud Al-Soki**
*****Diana Hussein Al-Hassan**

Abstract

Artificial intelligence is one of the areas that has attracted the attention of researchers in this era, given its importance in imitating the human mind in solving complex problems, and the applications of artificial intelligence in robots are very important in developing its performance.

In this research, a study was presented on the design and implementation of a system for teaching robots using artificial intelligence. The study was also carried out on the robot (HBE-RoboCAR) with the addition of proposed modifications to the robot to make it learn according to artificial intelligence algorithms. The study included the detailed components of the robot and the addition of Raspberry PI, which represents the mind capable of Processing artificial intelligence algorithms (deep learning), an artificial intelligence algorithm was implemented based on the deep learning network (CNN) to distinguish people who wear a mask, and a classifier (HAAR cascade) was relied on to identify faces, where a program was implemented to distinguish people who wear a mask from people who not wearing it, the robot was a future for visitors. A set of experiments was conducted on the proposed robot, where 60% of a global database was used in the training phase (model building), and 90% accuracy was obtained for training**.**

Keywords: artificial intelligence, deep learning, Raspberry PI, robot (HBE - RoboCAR).

*****Assistant Professor, Informatics College, AL-Assad Academy, For Military Engineering
**Engineer, Informatics College, AL-Assad Academy, For Military Engineering
***Engineer, Informatics College, AL-Assad Academy, For Military Engineering

1- مقدمة (Introduction):

يعتبر الذكاء الصنعي حجر الأساس للعصر الحديث، حيث تقوم أغلب الشركات بإجراء العديد من الاختبارات من أجل تطوير أنظمة الذكاء الصنعي، وتقوم الكثير من الشركات حالياً بالاعتماد على أنظمة الذكاء الصنعي لتطوير نظامها التجاري والصناعي والتواصل مع العملاء لحل مشاكلهم [1].

تم استخدام الذكاء الصنعي في الروبوت لمحاكاة الذكاء البشري في أداء الوظائف والمهام المتعددة، وقد استطاعت العديد من الشركات الحصول على نماذج تستطيع التحدث مع البشر بشكل طبيعي وأداء مهام البشر المختلفة وتحليل الصور والمعلومات. يقدم هذا النوع من الذكاء الكثير من الميزات حيث يستطيع الروبوت أن يؤدي وظيفة طوال اليوم وعلى مدار الأسبوع دون أن يشعر بالملل أو الإرهاق أو يأخذ وقتاً للراحة، وكذلك يؤدي الوظيفة المطلوبة منه وفقاً للمعايير المدخلة له سابقًا بشكل دقيق ودون أي خلل طول فترة عمله [2].

هناك العديد من الدراسات التي قدمت في مجال استخدام الذكاء الصنعي والروبوت ومنها:

قدم الباحث (Tai Lei) في عام (2016) بحثاً بعنوان (استراتيجية الاستكشاف للروبوت المعتمدة على شبكة التعليم Q-Network)، حيث يقدم هذا البحث آليةً لاستخدام التعلم المعزز كطريقة لاستكشاف بيئة ممر من خلال المعلومات المقدمة من حساس RGB-D، حيث يتم التحكم بالروبوت لتجنب العقبات من خلال التدريب المسبق، وقد تم الحصول على نتائج جيدة لأداء الروبوت [3].

قدم الباحثون (Zetao Chen, Adam Jacobson, *et al*) في عام (2017) بحثاً بعنوان (ميزات التعلم العميق في نطاق التعرف البصري على المكان). تم في هذا البحث الاعتماد على الشبكة العصبية التلافيفية للتعرف على مكان محدد، كما تم العمل على تطوير مجموعة بيانات ضخمة خاصة بالمواضع (SPED) مع مئات الأمثلة التي تعتمد على تغيير مظهر المكان. بعد تدريب الشبكة بشكل شامل على العديد من مجموعات

بيانات التعرف على الأماكن المعيارية الصعبة ثبت أنها تحقق كمتوسط زيادة بنسبة 10% في الأداء مقارنة بخوارزميات التعرف الأخرى [4].

قدم الباحث (ماهر خلف حسين وآخرون) في عام (2017) بحثاً بعنوان (تصميم وتحليل أسلوب جديد لتمييز الوجوه باستخدام تقنية الشبكات العصبونية وبالاعتماد على شبكة ايلمان). في هذا البحث تم اقتراح نظام لتمييز الوجوه، يستخدم هذا النظام خوارزمية تحليل المركبات الأساسية في استخلاص الميزات المهمة من صور الوجوه في قاعدة البيانات, ويستخدم الشبكة العصبونية من نوع ايلمان في عملية التمييز، حيث تم اختبار الأسلوب المقترح بعد بناءه باستخدام الحزمة البرمجية ماتلاب وأعطت نتائج دقة 90% [5].

قدمت الباحثة شغاف عبدالله في عام (2019) رسالة بعنوان (الكشف عن العربات من صور جوية باستخدام خوارزميات التعلم العميق وتنفيذ روبوت متحرك). تمحور هذا البحث حول استخدام طرق التعلم العميق من أجل كشف الأهداف في الصور الجوية، تم التركيز في هذا البحث على خوارزمية (YOLOv3) للتعلم العميق، حيث تم اقتراح بنية تساعد على كشف الأجسام من الصور الجوية بتطوير هذه الخوارزمية وأعطت نتائج تحسين بنسبة 95% [6].

قدم الباحثان (Chakarova and Traber) في عام (2019) دراسة بعنوان (أنا الروبوت، وجدت لمساعدتك يا أمين المكتبة). تمحور هذا البحث على أهمية الروبوتات بالنسبة لأمناء المكتبات، وقد أجرى فيها الباحثان دراسة استطلاعية على عدد من المكتبات الجامعية في تسع دول أوروبية، وتسع دول آسيوية.

توصلت الدراسة إلى جملة من النتائج أهمها أن الروبوت يؤدي خدمات جليلة للمكتبات بعضها بسيط والآخر أكثر تعقيداً [7].

قدم الباحثون (Sorin Grigorescu, Bogdan Trasnea, *et al*)) في عام (2019) دراسة حول (استخدام تقنيات التعلم العميق للقيادة الذاتية) بهدف الاطلاع على أحدث ما توصلت إليه تقنيات التعلم العميق المستخدمة في القيادة الذاتية. تعتمد هذه الدراسة على

الشبكات العصبية التلافيفية والمتكررة، بالإضافة إلى نموذج التعلم المعزز العميق، تساعد المقارنة المقدمة في هذا الاستطلاع في الحصول على نظرة ثاقبة لنقاط القوة والقيود في التعلم العميق، وأساليب الذكاء الصنعي للقيادة الذاتية والمساعدة في خيارات التصميم [8].

قدم الباحثان (Adlamani Ravi and Richard Alan) في عام (2019) دراسة حول (التعلم العميق مع التركيز بشكل خاص على البنى والتطبيقات والاتجاهات الحديثة)، حيث قدما في هذه الدراسة لمحة عامة عن بعض الشبكات العصبونية متعددة الطبقات، وهيكلية الشبكة العصبونية العميقة، وكيفية استخدام الشبكات العصبونية، وأسلوب التعلم العميق لاكتشاف الأخطاء وتقليل الخطأ لاحقاً. تعتبر هذه الدراسة مرجع مفيد للباحثين الذين يسعون إلى استخدام التعلم العميق في التعرف على الأنماط الإحصائية من أجل أفضل أداء [9].

قدم الباحثون(Osama Mazhar, Benjamin Navarro, *et al*) في عام 2020 رسالة بعنوان (إطار التفاعل بين الإنسان والروبوت في الوقت الفعلي مع اكتشاف لإيماءات اليد الثابتة)، حيث يعمل هذا البحث على تصميم إطار عمل موثوق للتعاون الآمن في الزمن الحقيقي بين الإنسان والروبوت باستخدام إيماءات اليد الثابتة واستخراج الهيكل العظمي ثلاثي الأبعاد, كما تم تسجيل مجموعة بيانات للصور لإيماءات اليد الثابتة بالأبجدية الرقمية مأخوذة من لغة الإشارة الأمريكية. بنيت الشبكة العصبية التلافيفية ودربت على اكتشاف إيماءات اليد، وفي النتيجة تم الحصول على دقة بنسبة 98.9% [10].

قدم الباحثون (Rabab Benotsmane, L. Dudás, *et al*) في عام 2020 رسالة بعنوان (دراسة حول خوارزميات الذكاء الصنعي المستخدمة في الروبوتات الصناعية)، تقدم هذه المقالة نظرة عامة عن خوارزميات الذكاء الصنعي المستخدمة في الروبوتات الصناعية،

وقد تم توضيح خوارزميات التعلم الآلي، وعرض أهم خوارزميات الذكاء الصنعي المستخدمة لتحسين مسار الأسلحة الآلية [11].

قدم الباحثون (Barbosa Pinto ،Tiago Alexandre, *et al*) في عام 2020 رسالة بعنوان (الكشف عن الأشياء بالرؤية الصنعية والشبكات العصبونية لروبوتات الخدمة). تم الاعتماد في هذا البحث على التعلم العميق لتنفيذ أنظمة يمكنها التعلم من البيانات المقدمة دون الحاجة إلى ترميزها، وذلك لتقليل التعقيد واستهلاك الوقت والاعتماد على الشبكة العصبية التلافيفية CNN للتعرف على الأنماط والحواف من بيانات الصورة. تم في نهاية هذا البحث تقديم نموذج جيد يسمح بالكشف عن الأشياء في الزمن الحقيقي [12].

قدم الباحثان (Ming Xiao and Nanfeng Xiao) في عام (2020) رساله بعنوان (الشبكة العصبية التلافيفية المحسنة للتعرف على الكائنات معتمدةً على الانسان الآلي)، حيث تم في هذا البحث اقتراح الخوارزمية المثلى باستخدام الشبكة العصبية التلافيفية، والتي تم استخدامها لاكتشاف وتصنيف الكائنات بواسطة الروبوتات، واستخدمت الشبكة المحسنة (Faster R-CNN)، وتم الحصول على أداء جيد نسبيًا [13].

2- أهداف البحث:

الهدف الأساسي من هذا البحث هو:

- ❖ تصميم وتنفيذ نظام لتعليم الروبوتات باستخدام الذكاء الصنعي، حيث يعمل الروبوت كموظف استقبال ينفذ ما يلي:
  - اكتشاف الوجوه في الصور.
  - تمييز الأشخاص الذين يرتدون قناع عن الأشخاص الذين لا يرتدون قناع.
  - مرافقة الشخص الذي يرتدي قناع إلى القاعة، وتشغيل جهاز إنذار في حال عدم ارتداء القناع.

3- التعلم العميق (Deep Learning)

هو أحد فروع تعلم الآلة (Machine Learning)، والذي يهتم بشكل أساسي بتطوير خوارزميات تُمكن الحاسب الآلي من تعلم كيفية أداء المهام الصعبة التي تتطلب فهماً عميقاً للبيانات، وطبيعة عملها كتشخيص الأمراض باستخدام التصوير الطبي. يعتمد التعلم العميق بشكل أساسي على الشبكات العصبونية Artificial Neural Networks، ويوضح الشكل (1) ارتباط التعلم العميق بتعلم الآلة والذكاء الصنعي [14].

الشكل (1): ارتباط التعلم العميق بتعلم الآلة والذكاء الصنعي[14].

أظهرت الاكتشافات في هذا المجال تقدماً كبيراً وسريعاً وفعالية في العديد من المجالات منها التعرف على الوجه، التعرف على الكلام، الرؤية الحاسوبية، ومعالجة اللغات الطبيعية. تتعلم الآلة من البيانات الضخمة باستخدام تصميمات مختلفة لشبكات التعلم العميق منها: الشبكات المتكررة (RNN) المستخدمة بكثرة مع النصوص والبيانات المستمرة، والشبكة العصبونية التفافية (CNN) التي تستمد إلهامها من العمليات البيولوجية في الفص البصري، وغيرها من التصميمات [15].

4- البنية المعمارية لشبكة التعلم العميق:

تتألف الشبكات العصبونية بشكل عام من ثلاثة أنواع من الطبقات وهي طبقة الدخل المسؤولة عن إدخال البيانات بشكلها الطبيعي إلى الشبكة العصبونية بعد عملية النمذجة، وطبقة الخرج المسؤولة عن إصدار النتيجة النهائية للشبكة العصبونية، ويقع بين

هاتين الطبقتين عدد من الطبقات التي تعمل على تحويل بيانات الدخل إلى الخرج المطلوب، وتسمى هذه الطبقات بالطبقات الخفية (Hidden Layers)، وذلك لغموض طريقة توزيع البيانات بين طبقتي الدخل والخرج. يرمز البعض إلى هذا النوع من الخوارزميات بالصندوق الأسود [16].

يوضح الشكل (2) هيكلية الشبكة العصبونية ذات طبقتين خفيتين، وعدد غير محدد من العصبونات في كل طبقة.

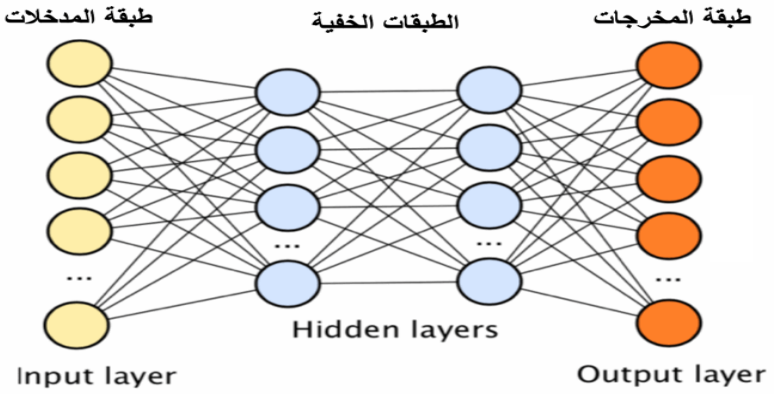

الشكل (2): هيكلية الشبكة العصبونية ذات طبقتين خفيتين [16].

تحتوي كل طبقة من الطبقات الخفية على عدد معين من العصبونات التي تستقبل البيانات من عصبونات الطبقة السابقة، ومن ثم تجري عليها عملية رياضية غير خطية وترسلها إلى الطبقة التالية، وهكذا حتى آخر طبقة (طبقة الخرج).

سيتم التحدث عن واحدة من أهم الشبكات العصبونية في التعليم العميق وهي الشبكة العصبونية التلافيفية والتي تم الاعتماد عليها في هذا البحث.

5- الشبكات العصبونية التلافيفية (Convolutional Neural Networks):

إحدى شبكات التعليم العميق، والتي تختلف بنيتها عن الشبكات العادية، حيث تتعامل مع الصور وتعطي السمات دون الحاجة لتقنيات استخلاص السمات. يوضح الشكل (3) بنية الشبكة العصبونية التلافيفية وأنواع الطبقات الموجودة فيها [17]:

- Conv layer.
- RELU layer.

- Pool layer.
- Fully connected layer (FC).

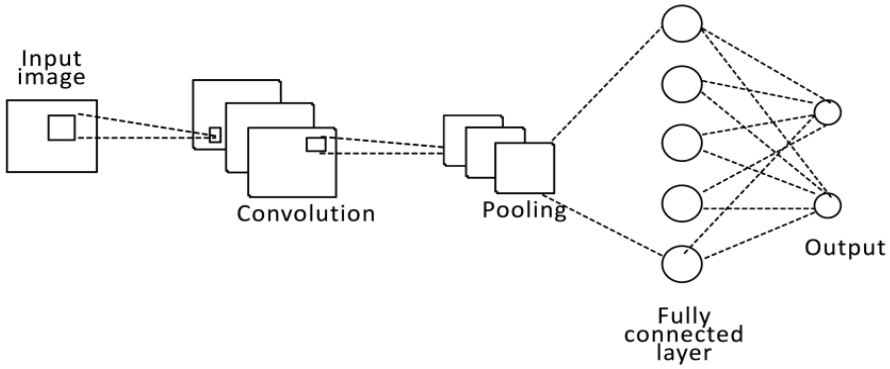

الشكل (3): بنية الشبكة العصبونية التلافيفية [17].

يكون دخل الشبكات العصبونية شعاع وحيد تستقبله وتحوله عبر سلسلة من الطبقات المخفية. كل طبقة مخفية تكون عبارة عن مجموعة من العصبونات يتصل كل عصبون منها مع جميع عصبونات الطبقة السابقة له. تدعى الطبقة الأخيرة بطبقة الخرج.

لتوضيح عملية تدريب الشبكة العصبية الترشيحية (شبكة الالتفاف) Convolution Network يمكن تلخيصها في الخطوات التالية [17]:

1. نقوم بتهيئة كل المرشحات والمعاملات والأوزان بقيم ابتدائية عشوائية.
2. تقوم الشبكة بأخذ صورة التدريب المدخلة وتمر بعملية الانتشار الامامي forward propagation), الالتفاف(Convo)، الريلو(ReLU)، التجميع(pooling) بالإضافة للانتشار الامامي في الطبقة (FC)) ثم تقوم باستخراج احتمالات التصنيف لكل فئة, بما أن الأوزان هي أوزان عشوائية في الخطوة الأولى في عملية التدريب فإن احتمالات التصنيف المخرجة ستكون عشوائية أيضاً.
3. حساب مجموع الخطأ في طبقة الخرج، باستخدام المعادلة التالية:

$$\text{Total Error} = \sum \tfrac{1}{2}\,(\text{target probability} - \text{output probability})^2 \quad (1)$$

4. استخدام الانتشار العكسي لحساب مشتقة الخطأ مع تحديث جميع قيم المرشحات والأوزان والمعاملات لتقليل نسبة الخطأ في الخرج. يتم تعديل الأوزان بما يتناسب مع مساهمتها في الخطأ الكلي. بعض المعاملات مثل عدد المرشحات، حجم

المرشحات، نوع بناء الشبكة ... الخ تكون ثابتة ولا تتغير خلال عملية التدريب، الذي يتغير هو قيم مصفوفات المرشحات والأوزان يتم تحديثها فقط.

5. إعادة تنفيذ الخطوات من 2 الى 4 مع كل الصور المدخلة في مجموعة التدريب.

بعد التعرف على بنية الشبكة العصبية التلافيفية، لابدَّ من توضيح مواصفات الروبوت الذي تم العمل علية والتعديل المقترح.

6- مواصفات الروبوت (HBE-RoboCAR) التفصيلية:

هو روبوت على شكل سيارة، كما هو موضح في الشكل (4) , حيث تتكون وحدة القيادة للروبوت من معالج دقيق داخلي (ATmega128L) مدعم بأجهزة استشعار (حساسات) مختلفة، ومحركات بالإضافة الى التحكم الذكي في الروبوت من خلال وحدات المعالجات الدقيقة المدمجة متعددة الأشكال، وإمكانية الكشف عن العوائق باستخدام الحساسات المتنوعة [18].

الشكل (4): هيكل الروبوت (HBE-RoboCAR) [18].

يمكن توضيح مواصفات الروبوت (HBE-RoboCAR) وفق الجدول (1):

الجدول (1): مواصفات الروبوت (HBE-RoboCAR) [18].

الميزات	HBE-RoboCAR
المتحكم	ATmega128
حجم الذاكرة	128 كيلو بايت
نوع الحساسات	Ultrasonic sensor PSD sensor Phototransistors

نوع المحركات	DC geared motor
وحدات التوسيع	وحدة الكاميرا HBE-RoboCAR- vision RoboCAR- embaded
لغة البرمجة المستخدمة	C ++ 6.0 تدعمها مكتبات OpenCV امكانية التطوير واستخدام اصدارات Linux ، C #، VC
التطبيقات الممكنة على الروبوت	التحكم الذكي في الروبوت من خلال وحدات التوسيع الإضافية متعددة الأشكال، التي يمكن تركيبها على الروبوت، وتجارب واختبارات باستخدام الحساسات المختلفة (الكشف عن العوائق، تتبع مسار أرضيه محدد). وتجربة التحكم اللاسلكي

7- التطبيق المقترح:

يمكن توضيح النظام المقترح للروبوت عن طريق المخطط الصندوقي الموضح في الشكل (5) الذي يبين المكونات الداخلية للروبوت مع الإضافات المقترحة.

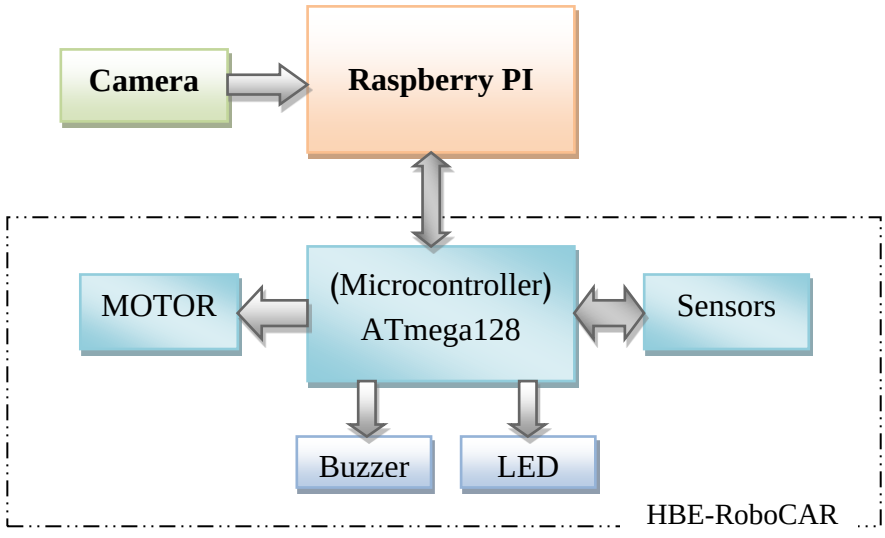

الشكل (5): المخطط الصندوقي لنظام التحكم.

بناء على ما ذُكر سابقا فإن الآلية التي تم اقتراحها لتطوير الروبوت هي إضافة Raspberry PI، حيث تم الربط عن طريق منفذ التوسيع الخاص بالروبوت, يوضح الجدول (2) الأقطاب التي يمكن توصيلها لتأمين الربط بين روبوت HBE-(RoboCAR) ولوح Raspberry PI بحيث تتم معالجة خوارزميات الذكاء ضمن العقل، وإعطاء الأوامر للجسم للقيام بردة الفعل المناسبة للقرار المتخذ.

الجدول (2): توصيل Raspberry PI مع HBE-RoboCAR.

Raspberry PI	.HBE-RoboCAR
GND	GND
RXD	TXD
TXD	RXD

يوضح الشكل (6) الروبوت المُعدل في النموذج المقترح من مسقط جانبي وعمودي، مع إظهار التوصيلات التي تربط الروبوت المقترح مع Raspberry PI الذي تم إضافته.

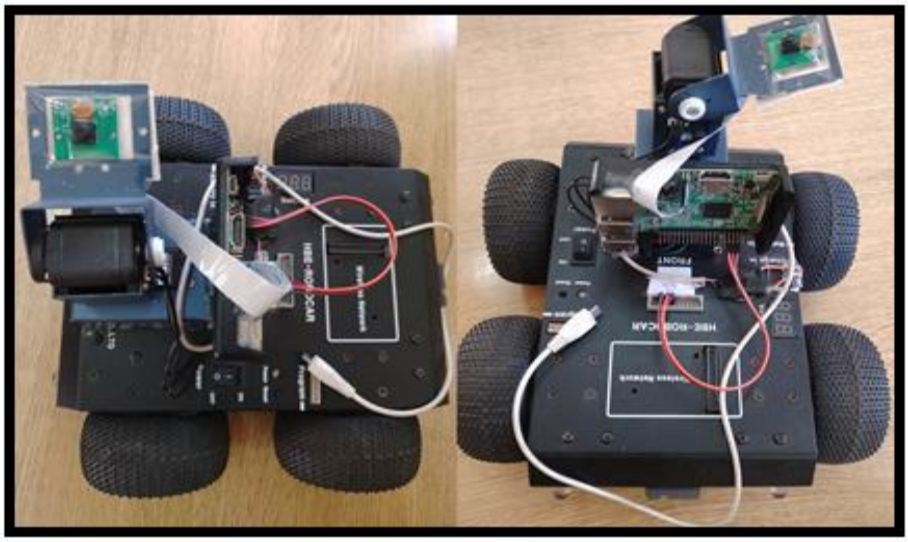

الشكل (6): الروبوت المُعدل في النموذج المقترح من مسقط جانبي وعمودي.

تم في هذا التطبيق كشف قناع الوجه (الكمامة الطبية) في الزمن الحقيقي مع (Python) باستخدام التعليم العميق لاكتشاف فيما إذا كان الشخص الموجود على كاميرا الويب

يرتدي قناعًا أم لا، حيث تم تدريب نموذج كاشف قناع الوجه بالاعتماد على مكتبات (OpenCV, Keras). تم تحميل مجموعة البيانات التي تتكون من 1376 صورة 690 صورة منها تحتوي على صور لأشخاص يرتدون أقنعة، و686 صورة لأشخاص بدون أقنعة. يمر التطبيق الخاص بالنظام المقترح بمرحلتين كما هو موضح في الشكل (7) وهما:

المرحلة الأولى: يتم فيها كتابة كود برمجي باستخدام لغة البايثون بالاعتماد على مكتبة Keras، وإنشاء شبكه التعليم العميق (CNN) التي تم توضيحها سابقا من أجل تدريب نموذج كاشف قناع الوجه باستخدام قاعدة البيانات التي تم تحميلها.

المرحلة الثانية: تُستخدم لاختبار النتائج باستخدام كاميرا Raspberry Pi في الزمن الحقيقي عن طريق مكتبة OpenCV والموديل الناتج من المرحلة الأولى لتمييز حالة الشخص فيما اذا كان يرتدي قناع أو لا.

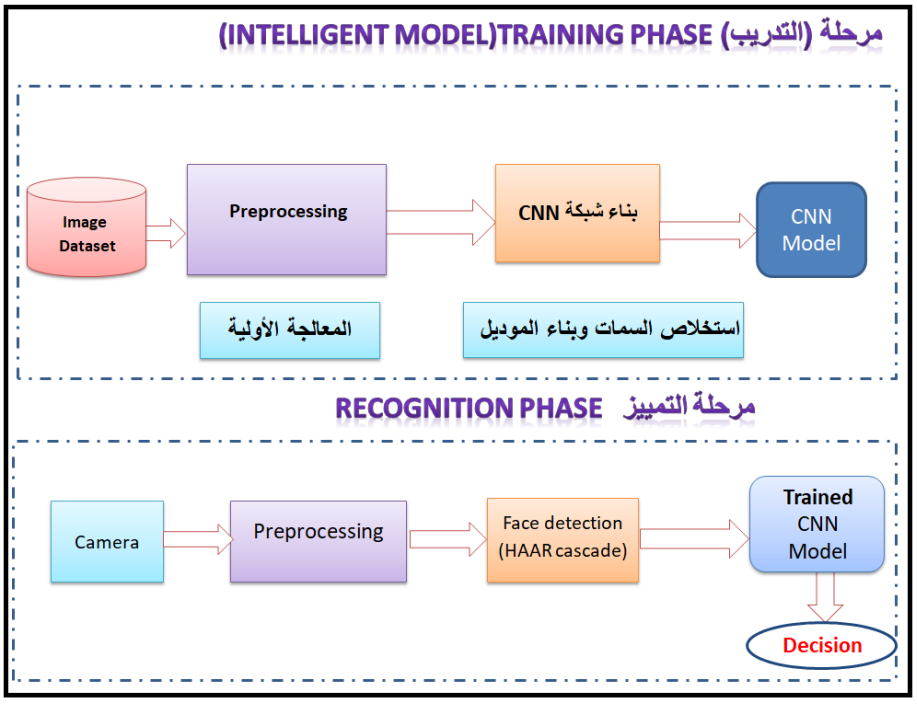

الشكل (7): مراحل كشف قناع الوجه في الزمن الحقيقي.

تدعى المرحلة الأولى بمرحلة التدريب، وتتم فيها عملية المعالجة الأولية المتمثلة في تحديد الوجوه ضمن الصور المأخوذة من قاعدة البيانات، وبعد ذلك يتم إنشاء شبكة الالتفاف في التطبيق المقترح المكونة من زوجين من طبقات Conv و MaxPool لاستخراج الميزات من مجموعة البيانات, وبعد ذلك تأتي طبقة Dropout (التي تُظهر أن العصبونات في الطبقة السابقة تمتلك احتمالية تعطل أثناء التدريب)، ثم طبقتي Dense كثيفتين من أجل عملية التصنيف باستخدام توابع (relu, softmax). يتم إنشاء شبكة الالتفاف (CNN) وفق التعليمة التالية في بايثون:

```
model = Sequential([Conv2D(100, (3,3), activation='relu', input_shape=(150, 150, 3)),
                    MaxPooling2D(2,2),
                        Conv2D(100, (3,3), activation='relu'),
                        MaxPooling2D(2,2),
                        Dropout(0.5),
                        Dense(50, activation='relu'),
                        Dense(2, activation='softmax')
```

يُظهر الجدول (3) النتائج التي تم الحصول عليها في نهاية مرحلة تدريب نموذج الشبكة المقترح الذي تم الاعتماد عليه، والذي يبين قيم (loss, Accuracy) عند كل تكرار لتدريب للشبكة، فقد تم تحديد عدد التكرارات ب 5 تكرارات, وكانت كافية لتدريب الشبكة بشكل جيد.

الجدول (3): قيم (loss, Accuracy) عند كل مرور.

LOSS	ACCURACY	EPOCH
0.7737	0.5904	Epoch(1)
0.3710	0.8618	Epoch(2)
0.2876	0.8879	Epoch(3)
0.3243	0.8692	Epoch(4)
0.2661	0.9009	Epoch(5)

يمكن حساب تابع (loss) وفق المعادلة التالية:

$$loss = -(y * (\log\ (p) + (1 - y) * \log\ (1 - p)) \dots\dots\dots\dots . (2)$$

حيث: y قيمة الخرج الحقيقي, p قيمه الخرج المحسوب.

يمكن حساب الدقة (Accuracy) وفق المعادلة التالية:

$$Accuracy = ((TP + TN) / (TP + TN + FP + FN)) \dots \dots (3)$$

حيث:

TP(True positive): عدد التنبؤات التي نجح فيها النموذج في تعرف الأنماط الصحيحة، مثلاً الشخص يرتدي قناع والنموذج تنبأ بذلك.

FP(False positive): عدد التنبؤات التي فشل فيها النموذج في تعرف الأنماط الصحيحة.

TN(True Negative): عدد التنبؤات التي نجح فيها النموذج في تعرف الأنماط الخاطئة.

FN(False Negative): عدد التنبؤات التي فشل فيها النموذج في تعرف الأنماط الخاطئة.

يمكن توضيح العلاقة بين الدقة وتابع (loss) وعدد تكرارات التدريب من خلال الشكل (8)، حيث أن الدقة تتزايد مع عدد مرات التدريب، بينما تابع الفقدان يتناقص.

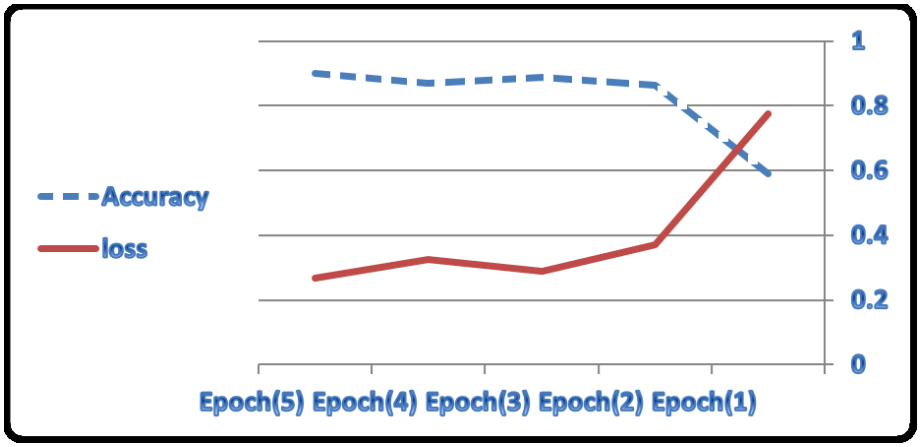

الشكل (8): العلاقة بين الدقة وعدد تكرارات التدريب.

المرحلة الثانية تُدعى بمرحلة التمييز، ويتم فيها اختبار النتائج باستخدام كاميرا Raspberry Pi لتمييز الشخص فيما إذا كان الشخص يرتدي قناع أو لا. تعطى الأوامر إلى الروبوت بناءً على القرار المتخذ للقيام بالإجراء المناسب كما هو موضح في الشكل (9).

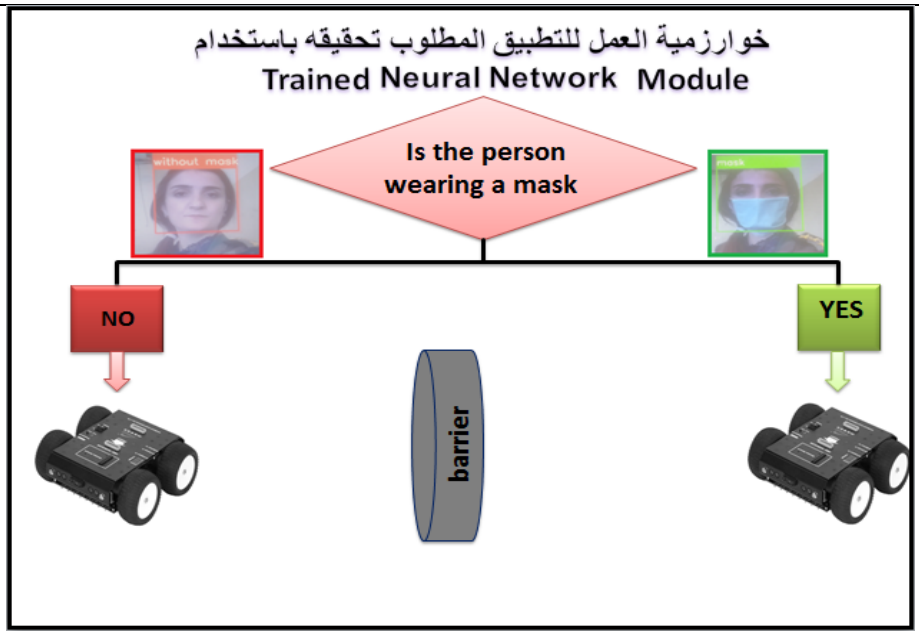

الشكل (9):مرحلة التمييز في الزمن الحقيقي.

كما سيتم ارسال الأوامر بين Raspberry والمتحكم الداخلي للروبوت عن طريق المنفذ التسلسلي للروبوت. يتم تهيئة الروبوت عن الطريق تعليمة بايثون التالية:

```
ser = serial.Serial( port='/dev/serial0', baudrate = 9600,
parity=serial.PARITY_NONE,stopbits=serial.STOPBITS_ONE,
 bytesize=serial.EIGHTBITS)
```

بعد تهيئة المنفذ ينتقل التحكم الى الروبوت بناءً على القرار المتخذ, حيث توضح الخوارزمية في الشكل(10) عمل المتحكم الداخلي للروبوت بعد تلقي الأمر من Raspberry.

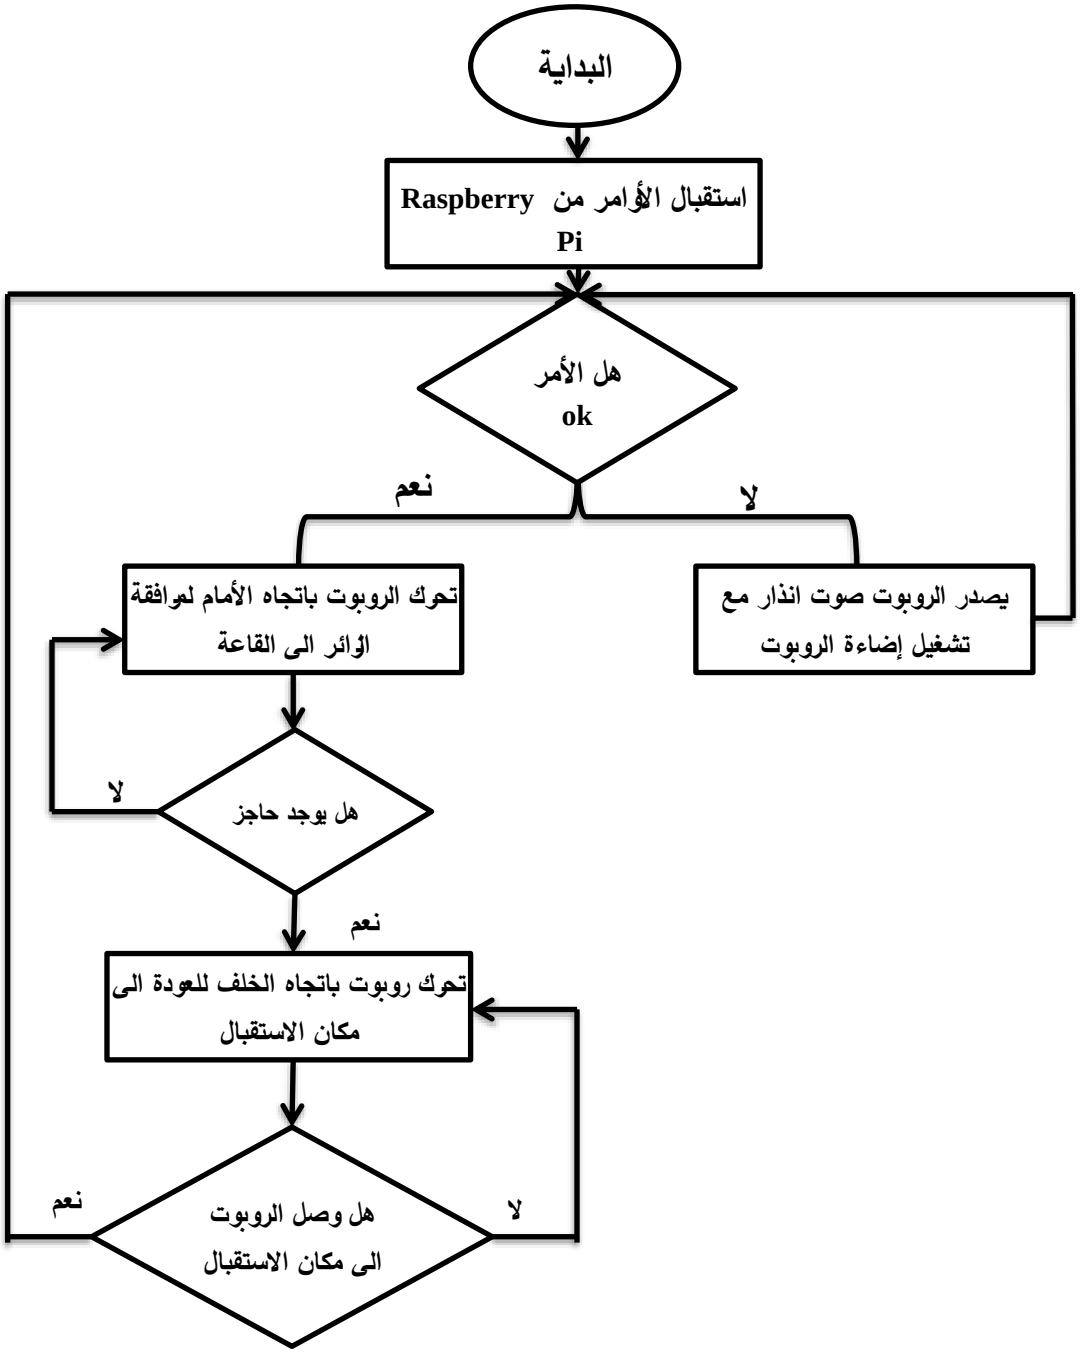

الشكل (10): خوارزمية عمل المتحكم الداخلي للروبوت.

8- الملخص (Summery):

بناء على المراحل السابقة تم تصميم روبوت استقبال، كما تم اجراء اختبار الروبوت على مجموعة مؤلفة من (30) طالب يدخلون إلى قاعة وتم الحصول على زمن اكتشاف لكل طالب (2 - 3 sec).

تم في هذا التطبيق إنجاز عملية التمييز في الزمن الحقيقي فيما إذا كان الشخص الموجود على كاميرا الويب يرتدي قناعًا أم لا باستخدام التعليم العميق. تم تدريب النموذج المقترح بالاعتماد على مكتبات (OpenCV,Keras) وعلى مجموعة بيانات مكونة من 1376 صورة، وتم الحصول على دقة حوالي 90% في مرحلة التدريب.

9- الأعمال المستقبلية (Future Works):

بغية تطوير العمل المنفذ في هذا البحث يقترح الأتي:

- استخدام بورد التطوير **Raspberry PI4** بدلاً من **Raspberry PI3** المستخدم في هذا البحث لزيادة إمكانيات التطبيق المنجز.
- إضافة إمكانية التعرف على الوجوه بالإضافة إلى اكتشاف الكمامة.

10-المراجع (References):

[1] Bowden M., 2006- **Mind as Machine** ,Oxford University Press.

[2] Johnston J., 2008 **- The Attractiveness of Machine Life: Cybernetics, Artificial Life, and the New Artificial Intelligence**, MIT.

[3] Lei T., 2016- **A Robot Exploration Strategy Based on Q-learning Network**, Department of Mechanical University of Hong Kong.

[4] Chen Z., Jacobson A., Sünderhauf N., 2017-**Deep Learning Features at Scale for Visual Place Recognition**.

[5] منار عبد الكريم زيدان وماهر خلف حسين,2017 - **تصميم وتحليل أسلوب جديد لتمييز الوجوه باستخدام تقنية الشبكات العصبية بالاعتماد على شبكة ايلمان**, قسم هندسة البرمجيات, جامعة الموصل.

[6] شغاف عبدالله, 2019- **الكشف عن العربات من صور جوية باستخدام خوارزميات التعلم العميق وتنفيذ روبوت متحرك**, مركز البحوث قسم التحكم والروبوتيك.

[7] Chakarova, Traber, 2019- **I'm a robot, I found to help you, librarian**, Journal of Information Studies & Technology (JIS&T)

[8] Grigorescu S., Trasnea B., 2019 - **A study on the use of deep learning techniques for self-driving**, Transilvania University of Brasov.Brasov, Romania.

[9] Ravi A., Alan R., Peters, 2019 - **A Review of Deep Learning with Special Emphasis on Architectures, Applications and Recent Trends** , IEEE TRANSACTIONS

[10] Mazhar O., Navarro B., , Cherubin A., 2020- **Real-time Human-Robot Interaction Framework with Robust Background Invariant Hand Gesture Detection**, Computer Science.

[11] Benotsmane R., Dudás L., Kovács G., 2020 - **Survey on artificial intelligence algorithms used in industrial robotics** , Computer Science.

[12] Alexandre T., Pinto B., 2020- **Object detection with artificial vision and neural networks for service robots**, Minho's university.

[13] Xiao M., Xiao N., 2020- **Optimized Convolutional Neural Network-Based Object Recognition for Humanoid Robot**, China University.

[14] Goodfellow I., Bengio Y., Courville A., 2016- **Deep Learning**, MIT

[15] Bengio, Yoshua ,2009 - **Learning Deep Architectures for AI**, Université de Montréal.

[16] Derek C., Thomas P., Karnowski ,2010- **Deep Machine Learning A New Frontier in Artificial Intelligence Research**, IEEE COMPUTATIONAL INTELLIGENCE MAGAZINE.

[17] Saha S.,2019 - **A Comprehensive Guide to Convolutional Neural Networks the ELI5 way**, Published in Intel Student Ambassadors.

[18] dong G.,, Yuseong-gu, Daejeon, 2007- **www.hanback.co.kr**, Korea.