

Human Activity Recognition: Literature Review

Maisirreem A. Kamal¹, Dena Rafea Ahmed², Rashad Adhed Kamal³

^{1,2}College of Computer Sciences and Mathematics, University of Mosul, Mosul, IRAQ

³College of Engineering, University of Mosul, Mosul, IRAQ

E-mail: ^{1*} maisirreem_alsaigh@uomosul.edu.iq, ² dinasalimagha@uomosul.edu.iq, ³ rashad.alsaigh@gmail.com

(Received May 25, 2021; Accepted June 29, 2021; Available online December 01, 2021)

DOI: [10.33899/edusj.2021.130293.1162](https://doi.org/10.33899/edusj.2021.130293.1162), © 2021, College of Education for Pure Science, University of Mosul.

This is an open access article under the CC BY 4.0 license (<http://creativecommons.org/licenses/by/4.0/>).

ABSTRACT:

Human activity recognition has an important role in the interaction between human and human relationships because it provides information about a person's identity, personality, activities, psychological state, and health, all this information is difficult to extract due to the difficulty of a person's ability to identify the activities of another person and is considered one of the basic research topics in the scientific fields in the field of computer vision and machine learning. the purpose of human activity recognition (HAR) is to identify the different human activities throw monitoring and register the human activates and the various surrounded environment, by using computers, the human activity recognition researches which depending on visions is the basics of lots of applications even video monitoring or health care and security monitoring and the interaction between the human and the computers.

In this research, a review of the newest development in the human activity recognition branch have been studied, and the different ways to recognize the human actions, an important detail have been shown to preview the HAR researches and the methodologies used to represent the human activates and its classifications, to provide an overview of the HAR methods and comparing them.

Keywords: Human Activity Recognition(HAR) , machine learning algorithm, smart phone sensors, wearable sensor device.

تميز النشاط البشري: مقالة مرجعية

ميس الريم عضيد كمال^{1*}، دينا رافع احمد²، رشاد عضيد كمال³

قسم البرمجيات، كلية علوم الحاسوب والرياضيات، جامعة الموصل، الموصل، العراق
قسم الميكاترونكس، كلية الهندسة، جامعة الموصل، الموصل، العراق

الخلاصة:

يلعب التعرف على النشاط البشري دورًا مهمًا في التفاعل بين العلاقات الإنسانية والإنسانية لأنه يوفر معلومات حول هوية الشخص وشخصيته وأنشطته وحالته النفسية وصحته ، كل هذه المعلومات يصعب استخلاصها نظرًا لصعوبة قدرة الشخص على ذلك. التعرف على أنشطة شخص آخر وتعتبر من موضوعات البحث الأساسية في المجالات العلمية في مجال الرؤية الحاسوبية والتعلم الآلي.

يهدف التعرف على النشاط البشري (Human Activities Recognition (HAR)) إلى التعرف على الأنشطة البشرية من خلال مراقبه وتسجيل فعاليات الأشخاص والظروف البيئية المحيطة بهم باستخدام الحاسوب، حيث ان أبحاث التعرف على النشاط البشري القائمة على الرؤية هي أساس العديد من التطبيقات بما في ذلك المراقبة بالفيديو والرعاية الصحية و المراقبه الامنيه والتفاعل بين الإنسان والحاسوب.

في هذا البحث نقوم بمراجعته تسلط الضوء على التطورات في مناهج التعرف على الأنشطة البشرية باستخدام الحاسوب ودراسه طرق التعرف على الانشطه البشريه وتقديم رؤى تفصيلية حول الأعمال الحالية والمنهجيات المستخدمة من قبل الباحثين للتعرف على الأنشطة البشرية بالنسبة لتمثيل النشاط وطرق التصنيف. بهدف تقديم نظرة عامة على هذه الأساليب ومقارنتها.

الكلمات المفتاحية: تمييز النشاط البشري, خوارزميات التعلم الالي, مستشعرات الهواتف الذكية, الأجهزة الاستشعار القابلة للارتداء.

1-المقدمة: Introduction

لتمييز النشاط البشري دورًا مهمًا في التفاعل بين الإنسان والعلاقات الانسانيه (human-to-human interaction). وحيث ان التعرف علي النشاط البشري يحتاج الي العديد من التطبيقات التي تتطلب التفاعل بين الإنسان والحاسوب والروبوتات لتوصيف السلوك البشري نحتاج الي نظام التعرف على النشاط البشري.

من بين الكثير من التطبيقات لتمييز النشاط البشري يبرز السؤال المهم وهو "ما هو الإجراء المتخذ لمحاولة التعرف على الأنشطة البشرية"، حيث يجب أن تحدد الحالات الحركية للإنسان، بحيث يكون للحاسوب دور في التعرف على النشاط البشري بكفاءة، و يمكن دمج النشاط البشري مع البيانات البيئية المتصورة لتشكيل تمثيل كامل للنشاط البشري. يتم تضمين عدة خطوات في التعرف على النشاط البشري وهي اولاً تسجيل سلوك المستخدم لفترة زمنية، واستخراج المعلومات ذات الصلة من تسلسل السلوك، وتحليل بيانات التسلسل لاشتقاق أنماط محددة. تكشف هذه الأنماط نوعيه النشاط البشري وماذا يجب ان تقدم له من خدمات كما يمكن استخدام الأنماط لتقديم توصيات أكثر ملاءمة لهم.

تلعب الاتصالات والمنتجات الالكترونيه المحموله مثل الهاتف الذكي دورا مهما في التعرف علي النشاط البشري ويوجد حاليًا العديد من التطبيقات للمصلحة العامة حيث هناك حاجة ماسة إلى التعرف علي النشاط البشري على سبيل المثال: في الرعاية الصحية، لتصميم الأدوية للمرضى ذوي الإعاقة الذين يعانون من مشاكل حركية من خلال المراقبة المستمرة للحركة وأنشطة الحياة اليومية باستخدام أجهزة الاستشعار بالقصور الذاتي، وفي الأمن، لمراقبة الأماكن العامة ومنع الجريمة من خلال الكشف عن الأنشطة المتعلقة بالأمن باستخدام كاميرات الفيديو [1].

ومع ذلك فان التعرف علي النشاط البشري يعتبر مهمة معقدة بسبب عدة تحديات قد تواجه الباحثين مثل حركة المستشعر وكيفية تحديده وتحديد الفعاليه بصورة صحيحة بالإضافة الى الخلفية المزدهمة والغير منظمة والتنوع في كيفية تنفيذ الأنشطة البشرية المختلفة [2,3]. في هذه الدراسة تم دراسته العديد من البحوث والدراسات حول تقنيات التعرف علي النشاط البشري وتحليل التقنيات الاكثر شيوعا التي تعمل على تمييز والتعرف علي النشاط البشري ودراسة النماذج الحاسوبية والخوارزميات التصنيفية المتعلقة بها. وقد تم توضيح ومناقشة ايجابيات وسلبيات كل تقنية منهم.

قد تم تنظيم الدراسة على النحو التالي: القسم الثاني باختصار يقدم كيفية التعرف على النشاط البشري وكيفية تطبيقه في عدة مجالات، اما القسم الثالث فيصف انواع الاستشعار والتقنيات المستخدمة في انظمة تمييز النشاط البشري،القسم الرابع يناقش التحديات التي تواجه

مصممي انظمه التعرف علي النشاط البشري والقسم الخامس يوضح فيه الدراسات المتعلقة بطرق تمييز النشاط البشري التي تستخدم خوارزميات التعلم الالي والقسم السادس يوضح فيه التحديات لتصميم نظام التعرف علي النشاط البشري واخيرا يختتم القسم السابع بالاستنتاجات.

2- تمييز النشاط البشري

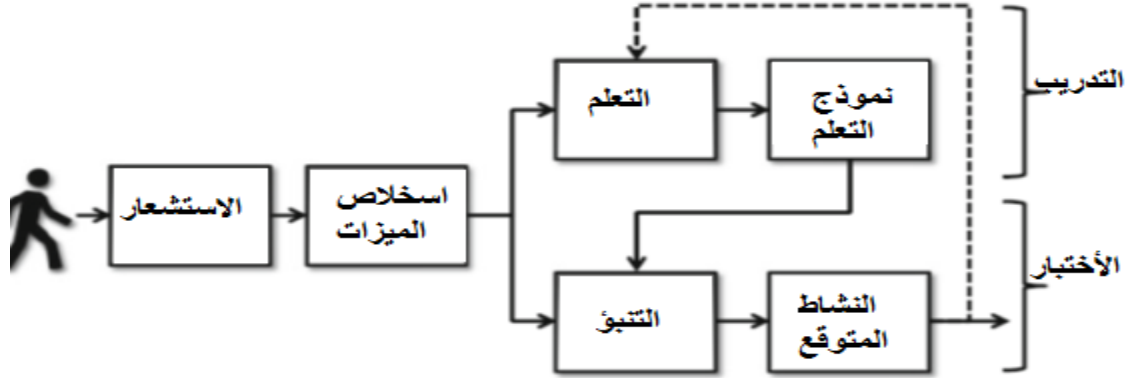
تعرف عملية تمييز النشاط البشري بانها القدرة على تفسير حركة جسم الانسان عبر اجهزة الاستشعار وتحديد نوعية هذا النشاط او الحركة . اغلب المهام اليومية للانسان من الممكن تبسيطها والتعرف عليها[4] . وقد يعمل نظام تمييز النشاط البشري تحت اشراف متخصصين او حتى بدون اشراف [5] حيث يتطلب الاشراف على هذا النظام بعض التدريب المسبق باستخدام بيانات معينة, اما عملية استخدام هذا النظام بدون اشراف فيتم ذلك بالاستعانة بمجموعة من القوانين خلال عملية الانشاء والتطوير[6].

لهذا فان دراسته و تصميم انظمه التعرف علي النشاط البشري له اهمية كبيرة في البحوث العلمية الحديثة حيث يدخل في عدة مجالات كالمراقبة الامنية ومجال الرعاية الصحية بالاضافة الى التفاعل البشري مع الحاسوب [6، 7، 8]

لقد تم اعتماد نظام التمييز البشري في عدة انظمة مثلا للمراقبة الامنية كمرقبة الاماكن العامة والبنوك والمطارات,حيث قدمت الكثير من البحوث بتصميم نماذج تقوم بالتنبؤ بالنشاط البشري لمنع حصول الجرائم والانشطة الخطرة في الاماكن العامة [5,9]. اما عند استعراض المراجع المتعلقة بالرعاية الصحية فان اغلبها قام باستخدام انظمة التعرف علي النشاط البشري المتوفرة في انظمة الرعاية الصحية في مناطقهم السكنية سواء اكانت في المستشفيات او مراكز اعادة التأهيل الخاصة بالمسنين او لادارة المراكز الخاصة بالامراض المزمنة او الوقاية منها. وكذلك قد تم دمج هذا النظام مع ما يسمى بالمنزل الذكية المخصصة لكبار السن لتتبعهم ومراقبة تحركاتهم وانشطتهم [10], كما يتم استخدام هذه الطريقة للتشجيع على ممارسة التمارين البدنية في مراكز اعادة التأهيل المخصصة للاطفال من ذوي الاعاقة البدنية , او لاعادة تأهيل المرضى بعد تعرضهم للسكتة الدماغية , والمرضى الذين يعانون من اي خلل وظيفي او تباطؤ حركي غير ذلك استخدم هذا النظام في عملية مراقبة المرضى في منازلهم, كمرقبة وحساب مقدار الطاقة المبذولة لتقليل السمعة المرضية وكذلك مراقبة صور المرضى وتحركاتهم وتحميلها على الحاسوب من اجل تحليلها [11,15].

ان اي نظام لتمييز النشاط البشري HAR يتكون من اربع مراحل اساسية، كما موضح في الشكل (1)[16]:

- **الاستشعار:** الاستشعار هو المسؤول عن تجميع بيانات المستشعر من المصادر المتوفرة ومعالجتها. بشكل عام, يجب اجراء عملية تكييف للاشارة كتقليل الضوضاء او رقمنة الاشارة وتحويلها من تماثلية الى رقمية وتضخيم الاشارة من اجل تكييف الاشارة المستلمة مع متطلبات التطبيق.[7، 16]
- **استخلاص الميزات:** في عمليه استخلاص الميزات تتم عملية استخلاص البيانات للحصول على مميزات ضرورية تصف البيانات وتسمح بتمثيل وتوضيح الحدث الاساسي بصورة افضل, يتم تحويل هذه البيانات المستخلصة الى مدخلات لخوارزمية تمييز. [7، 16]
- **التمييز:** في مرحله التمييز تستخدم خوارزميه التعليم , اما لتعلم ودراسة النموذج الحالي او التنبؤ بنشاط العينات الجديدة عند توفر النموذج.[7]



الشكل 1. خطوات تمييز النشاط البشري مع مراحل الاربعة الرئيسية [16]

1-2 التصنيف البشري

نظام تمييز النشاط البشري يعتمد على مجموعة من الأنشطة التي يجب دراستها والتعرف عليها لتأثيرها المباشر على طريقة تصميم وتنفيذ النظام. لهذا السبب، يتم تصنيف هذه الأنشطة الى فئات لتسهيل عملية اختيار الآلية المناسبة لفهم وتمييز النشاط البشري. يتم تصنيف الأنشطة البشرية تبعاً لمدتهم ودرجة تعقيدهم ونوع النشاط، الجدول (1) يوضح التصنيف تصنيف الأنشطة تبعاً لمدتها وتعقيدها [17,16].

جدول 1 . تصنيف الأنشطة البشرية بالاعتماد على مدتها وتعقيدها [17,16]

المدة/ التعقيد	نوع النشاط	الأمثلة
الاحداث القصيرة	ايماءات	تلويح اليدين/ الايماء بالرأس/ الضحك
	انتقالات	من الوقوف للجلوس/ من التمدد للجلوس
الاحداث الاساسية Basic Activities (BAs)	ثابتة	الوقوف/ الجلوس/ القراءة
	ديناميكي (متحرك)	المشي/ الركض/ ركوب الدرجات
الاحداث المعقده Complex Activities (CAs)	متعدد الأنشطة	الطبخ/ التجميع/ التاثير/ حمل الاوزان
	متعدد المستخدمين	التكلم/ الرقص/ العناق

كذلك من الممكن تصنيف الأنشطة بالاعتماد على نوعها، وبشكل عام هذه المجموعة من الأنشطة متصلة بالعديد من التطبيقات المختلفة، يوضح جدول (2) انواعاً مختلفة من الأنشطة التي تمت دراستها في العديد من البحوث السابقة [18,16].

جدول 2 . تصنيف الأنشطة البشرية تبعاً لنوعها [18,16]

التطبيق	الأمثلة
الأنشطة اليومية	مشاهدة التلفاز، كوي الملابس، تناول الطعام، الاستحمام، التنظيف
الحركة	المشي، ركوب الدراجة، الوقوف، الاستلقاء، السقوط
الرياضة/ اللياقة	القفز، رفع الاثقال، التسلق، السباحة
التواصل	الاتصال الهاتفي، المراسلة، التكلم، الغناء
الامان/ المراقبة	التسكع، المطاردة، الإشراف، المطاردة

3-تقنيات الاستشعار

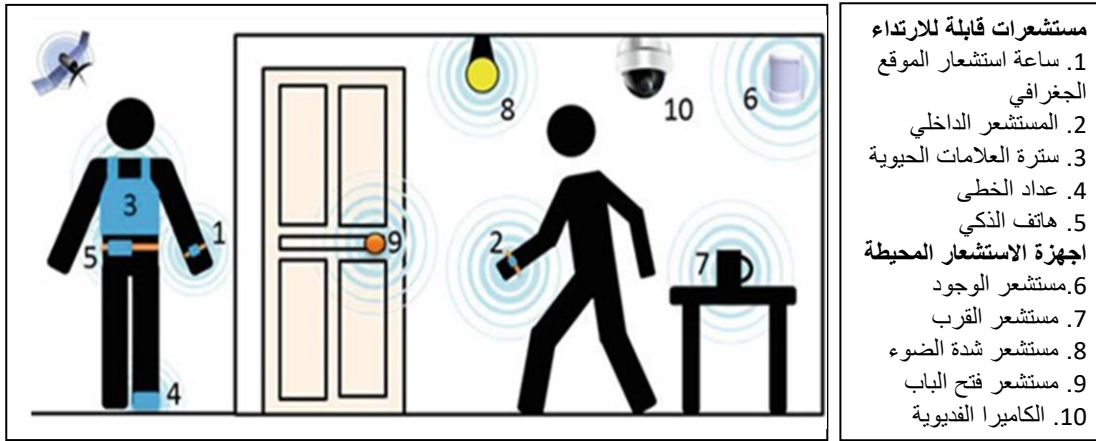
بشكل عام، تقنيات الاستشعار تلعب دوراً مهماً في التعرف وتمييز النشاط البشري، الشكل (2) يوضح كيفية التعرف على النشاط البشري، حيث عندما يقوم الإنسان بتحريك أي جزء من جسمه سواء يد أو قدم أو رأس ستقوم أجهزة الاستشعار بالتقاط هذه الحركة ونقلها إلى محرك بحث لتمييز وتحليل المعلومات وتحديد نوع الحركة التي قام بها الشخص. ويعد تحديد واختيار نوع جهاز الاستشعار الصحيح أحد أهم العناصر التي يجب مراعاتها عند تصميم أنظمة تمييز الأنشطة البشرية، حيث هناك عدة أجهزة استشعار قد تم اكتشافها لاستخلاص المعلومات المتعلقة بالتمييز. ويتم باستخدامها قياس وتحديد عدة سمات بما في ذلك العلامات الحيوية (مثل درجة حرارة الجسم ومعدل ضربات القلب وضغط الدم) والإشارات البيئية (مثل شدة الضوء ومستويات الصوت) والحركة (مثل التسارع والسرعة) وتحديد الموقع (مثل الموقع الداخلي والعالمي) [20,19,16].

المستشعر بالنسبة للمستخدم، يتم تصنيف اليات الاستشعار بالاعتماد عندما تكون المستشعرات قابلة للارتداء أو متصلة بجسم معين. يتم توضيح هذين التصنيفين في الشكل 2 مع ذكر امثلة عن كلا النوعين. [16، 19]

1- أجهزة الاستشعار المحيطة (Ambient Sensors)

أجهزة الاستشعار المحيطة، والمعروفة أيضاً باسم المستشعرات الخارجية أو البيئية، هي مجموعة من الأجهزة الموجودة في البيئة والتي تقيس الخصائص الفيزيائية فيما يتعلق بالمناطق المحيطة والمستخدمين الذين يشكلون جزءاً منها وتفاعلهم. هناك مجموعة واسعة من أجهزة الاستشعار المحيطة مثل الميكروفونات وكاميرات الفيديو ومستشعرات الوجود ومقاييس الحرارة وأجهزة استشعار العمق. تم بالفعل استخدام العديد من أجهزة الاستشعار هذه في HAR. على الرغم من أن أجهزة الاستشعار المحيطة تقدم معلومات دقيقة عن سياق حركة الإنسان وتكون الأنظمة القائمة على الفيديو فعالة جداً بالنسبة لـ HAR لكن هناك مخاوف الخصوصية، على سبيل المثال، عند استخدامها في بيئات المنزل لأن الناس بشكل عام غير مرتاحين بشأن استمرار مراقبتهم. ومن أنواع أجهزة الاستشعار المحيطة [16,17, 19]:

➤ مستشعر الوجود (Presence sensors): تكتشف أجهزة استشعار الوجود مسافة الجسم أو غيابه أو وجوده. / على سبيل المثال، شخص ما في المطبخ أثناء الصباح أثناء تشغيل آلة القهوة أن الشخص يقوم بإعداد وجبة الإفطار.



الشكل 2 . مثال على اجهزة الاستشعار للمجال المحيطوالقابلة للارتداء [16]

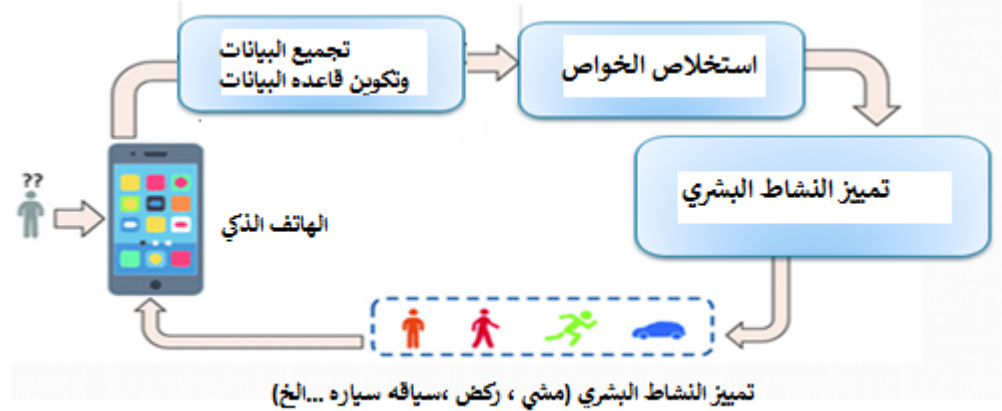
- مستشعر القرب (proximity sensors) : مستشعر القرب جهاز إستشعار قادر على اكتشاف وجود الأجسام القريبة منه بدون حدوث أي اتصال جسدي./ علي سبيل المثال أجهزة المحمول والشاشات التي تعمل باللمس وتقترّب من الوجه
- مستشعر شدة الضوء (Light intensity sensor): هو مكشاف حساس للضوء أو الإشعاع الكهرومغناطيسي .تستعمل المجسات الضوئية في القياسات الضوئية المختلفة أو لتشغيل أجهزة أو أدوات معينة، او لتحسس حركه شخص مثل قيامه بفتح الباب وقفله
- مستشعر فتح الباب (Open door sensor): وهو مستشعر يعرف ايضا باسم الباب التلقائي ، هو باب يُفتح تلقائيًا ، عادةً عند استشعار اقتراب شخص ما .
- الكاميرا الفديوية (Video camera sensor) d : يتم استخدام الكاميرات لتحليل الحركة البشرية القائمة على الرؤية بدون علامات.

2- مستشعرات قابله للارتداء (Wearable Sensors)

- تستخدم أجهزة الاستشعار القابلة للارتداء لجمع الإشارات مباشرة من المستخدمين. يتم ربطها عادةً بأجزاء مختلفة من الجسم مثل الخصر والمعصم والصدر والساقين والرأس ولكنها أيضًا متصلة بالملابس ويتم تضمينها في ملحقات أخرى للاستخدام المنتظم مثل الساعات والنظارات أو الهواتف المحمولة. ومن انواع مستشعرات قابله للارتداء: [19,17,16]
- ساعة استشعار الموقع الجغرافي (GPS sensor watch) : ساعة GPS عبارة عن جهاز به مستقبل GPS مدمج يتم ارتداؤه كوحدة واحدة مربوطة بمعصم بطريقة السوار. يمكن أن تحتوي الساعة على ميزات وإمكانيات أخرى حسب الغرض المقصود منها وتكون ساعة ذكية. غالبًا ما تستخدم ساعات GPS للأغراض الرياضية واللياقة البدنية>
 - المستشعر الداخلي (inertial sensor) :ي جهاز إلكتروني يقيس ويبلغ القوة المحددة للجسم ، ومعدل الزاوية ، وأحيانًا اتجاه الجسم
 - سترة العلامات الحيوية (Vital signs jacket): وهي سترة تلبس لقياس العلامات الحيوية (المعروفة أيضًا باسم العناصر الحيوية) هي مجموعة من أربع إلى ست علامات طبية مهمة تشير إلى حالة وظائف الجسم الحيوية (الحفاظ على الحياة). يتم أخذ هذه القياسات للمساعدة في تقييم الصحة البدنية العامة للشخص ، وإعطاء أدلة على الأمراض المحتملة ، وإظهار التقدم نحو الشفاء
 - عداد الخطى (pedometer) : عداد الخطى هو جهاز يحسب عدد الخطوات أو المسافة التي يقطعها أحد مشي
 - هاتف الذكي (Smart phone) : هو مصطلح يطلق على فئة من الهواتف المحمولة الحديثة التي تستخدم نظام تشغيل متطور، ومعظمها يستخدم شاشة اللمس واجهةً للمستخدم ويقوم بتشغيل تطبيقات المحمول

تستخدم اجهزه الاستشعار في انظمه التعرف علي النشاط البشري حيث تاخذ منها المعلومات وتحول من قبل مصمم نظام التعرف علي النظام البشري الي قيم رقميه لكل انظمه الاستشعار وتكون منها قاعده بيانات، وتعتبر قاعده البيانات ادخال الي خوارزميه التمييز والتعرف علي النشاط البشري، كمثال علي ذلك، الشكل (3)، حيث يستخدم الهاتف الذكي المحمول بواسطه الانسان كجهاز استشعار، و عن طريق المستشعرات الموجوده بالهاتف الذكي والبرنامج المصمم من قبل مصمم نظام التعرف علي النشاط البشري، يتم تحول اي

نشاط بشري الي قيم رقميه تخزن في قاعده البيانات، وتقسّم هذه البيانات الي بيانات تدريب وبيانات اختبار. وهذا العمليه تتطبق علي جميع اجهزه الاستشعار. [20,17,16]



الشكل (3) : تمييز النشاط البشري باستخدام المستشعر الهاتف الذكي [16]

4-التحديات التي تواجه مصممي نظام تمييز النشاط البشري

تصميم نظام تمييز النشاط البشري يعتمد على الانشطة التي يجب ان يقوم بتمييزها والتعرف عليها, حيث انه من الممكن ان تؤثر نوع الانشطة ودرجة تعقيدها على جودة التمييز, بعض التحديات التي يواجهها الباحثين في هذا المجال [16، 21]

- كيفية اختيار السمات المراد قياسها.
- كيفية بناء نظام التمييز ببيانات قابلة للنقل بين اكثر من جهاز الكتروني.
- كيفية استخراج الميزات وتصميم طرق الاستدلال.
- كيفية جمع البيانات في البيئة الحقيقية.
- كيفية التعرف على المستخدمين وعلى أنشطة المستخدمين الجدد دون الحاجة الى اعادة تدريب النظام.
- كيفية تطبيق النظام على اجهزة الهواتف المحمولة.

5- الخوارزميات المستخدمة لتصميم نظام تمييز النشاط البشري

استخدمت الخوارزميات التقليدية وخوارزميات الذكاء الاصطناعي والتعلم الآلي (Machine learning) في تصميم انظمه تمييز النظام البشري ومع التطور التقني السريع مثل الهواتف الذكية والساعات الذكية واجهزة الاستشعار القابلة للارتداء, ومع امكانيه تزويد هذه الاجهزة بتقنيات وتطبيقات الذكاء الاصطناعي للتنبؤ بالنشاط البشري, بالاعتماد على التسارع الحاصل لاشارة المستشعر اصبحت امكانيه تصميم انظمه تمييز النشاط البشري ممكنا [20]

الهدف الاساسي من انظمة تمييز النشاط البشري هو استخدام نموذج التعلم الآلي الذي يمتاز بالدقة العاليه لتنبأ النشاط البشري, وهناك عدة تقنيات تعلم تقليدية مثل Decision Tree, Random Forest, AdaBoost, Support Vector Machine, K-nearest

neighbor, Naïve Bayes, حققت دقة جيدة عند استخدامها مع تقنيات تمييز النظام البشري. ومع ذلك، وجد ان استخدام تقنيات التعلم الالي لتمييز النشاط البشري كان كفوءا جدا ، عند دراسة الكثير من الابحاث وجد ان هناك استراتيجيتين مختلفتين لبناء نموذج التعلم الالي [17].

- **النموذج التقليدي (Traditional model) :** في هذا النموذج يتم جمع البيانات من المستشعرات، ثم استخلاص الميزات، بعدها يتم استخدام احدى التقنيات الذكائية واخيرا تستخرج قائمة بالنشاطات البشرية.
- **نموذج التعلم الالي (Machine learning) :** في هذا النموذج يتم جمع البيانات، واستخراج الميزات، ثم استخدام احدى تقنيات التعلم الالي، واخيرا استخراج قائمة بالنشاطات البشرية. [22,17].

ونستعرض هنا بعض الدراسات والبحوث في مجال تمييز النشاط البشري، حيث ذكر الباحث Kantoch في سنة 2012 انه من خلال قراءة وتحليل عدد كبير من البحوث، وجد ان 56.25 % من الابحاث تركز على استخدام الخوارزميات التقليدية في التصنيف، وبعض الابحاث تعتمد على الخوارزمية التقليدية بالتشخيص لتحقيق الدقة العالية، و 33.33% تستخدم التعلم الالي، و 10.4% باستخدام الخوارزميات (التعلم الالي والخوارزميات التقليدية) لفحص واختبار النظام المقترح [24,23].

حيث قام Arifoglu et al. [25] بعمل مقارنة بين ثلاث انواع من الشبكات العصبية الحديثة، والتي تعد من خوارزميات التعلم الالي، مع خمس تقنيات تقليدية وهي SVMs, Naïve Bayes, HMMs, Hidden Semi-Markov Models, and Conditional Random Fields (CRFs), وتطبيقها على مجموعة من البيانات التي جمعت من قبل van et al. [26], وتم النقاط مجموعة من أنشطة الحياة اليومية مثل النوم والطهي ومغادرة المنزل وما الى ذلك باستخدام اجهزة استشعار موضوعة في المنزل لمدة تقارب الشهر، النتائج اظهرت بان التعلم الالي منافس متميز لانواع التعلم التقليدية.

كما قام الباحثون Slim, S. O., et al [24] بتطبيق الشبكة العصبية التلافيفية CNN في التعرف علي فعاليات الانسان وكذلك الشبكة العصبية الاصطناعية التراجعية RNN في التعرف علي فعاليات الانسان و اظهر البحث ان استخدام شبكة CNN لها فائدة كبيرة للتعرف علي فعاليات الانسان افضل من شبكة RNN

قام الباحثون Hayashi et al. [27] باستخدام الشبكة العصبية العميقة Deep Neural Networks (DNN) واقتراح طريقة جديدة تسمى دالة التوزيع التراكمي التجردية (ECDF) لتمثيل البيانات الناتجة من اجهزة الاستشعار لتحسين كفاءة استخراج المميزات [27,24].

الباحثون Nhac L., et al [28] قام بمقارنة اربع انواع من الخورزميات التقليدية (RF, NB, KNN, SVM) لاختبار نظام Mobile Online Activity Recognition System (MOARS) للتعرف تلقائيا على العديد من أنشطة مستخدم الهاتف الذكية [28].

الباحثون Kwapisz, J.R. et al [29] ركزوا على تطوير مجموعة من قواعد البيانات الخاصة التي جمعت باستخدام اجهزة الهواتف الذكية لتمييز النشاط البشري باستخدام الشبكات العصبية Multi-layer perceptron (MLP) و Logistic Regression و استخدموا لاختبار جودة وكفاءة مجموعة البيانات التي تم جمعها ال KNN هو التصنيف الاكثر شيوعا ويمكن ان يستخدم بشكل متكرر لتصنيف النظام الذي اقترحه الباحث او لمجرد المقارنة مع المصنف الرئيسي [29,24].

طور باحثون Bayat et al تصنيف جديد يعتمد على الدمج بين خوارزميات التصنيف التقليدية كما في [30] وهو مايسمى بالخوارزميات الهجينة .

[41] Brezmes, T. et al, استخدموا K-Nearest Neighbour في تنفيذ خوارزميات التعرف وتمييز الانماط اللازمة لتصنيف الحركات البشرية. لكنه لم يوفر معالجة مركزية للبيانات ولهذا فان مراقبة التحركات البشرية تتم بصورة لامركزية ولذلك يتطلب برنامج اضافي لكي يسجل ويبلغ عن التغييرات والتحركات البشرية.

[42] Sun, L., et al, قامو بتمييز الانشطة البدنية للأشخاص بوضع الهاتف المحمول بالقرب من منطقة الحوض. باستخدام Decision Tree, Naïve Bayes, Random Forest, Logistics Regression, و RBF Network, Support Vector Machine. ولكن النموذج معقدًا ويحتاج لتوفر العديد من الموارد الحاسوبية في الهاتف المحمول. ان الشبكات العصبية هي نموذج برمجي مستوحى من الناحية البيولوجية للإنسان ويمكن للحاسوب من التعلم من بيانات المستشعر والتعلم الآلي, وهو مجموعة قوية من التقنيات للتعلم في الشبكات العصبية. الشبكات العصبية NN حققت متوسط دقة مقبول. التعلم الآلي له بنى مختلفة مثل الشبكة العصبية التلافيفية (Convolution Neural Network CNN) والشبكة العصبية التراجعية (Recurrent Neural Network RNN) ولقد وجد الباحثون ان متوسط الدقة لجميع بيانات التعلم الآلي مقارنة بالغالب ولكن الأكثر استخداما هي CNN, جدول (3) يوضح اهم الطرق الذكائية المستخدمة في تمييز النشاط البشري وإيجابياتها وسلبياتها ودقة كل منها.

جدول 3. الطرائق التقليدية والذكائية في التعرف علي النشاط البشري

الباحثون	الخوارزميات	منهاج البحث	الإيجابيات	السلبيات	الدقة
Slim, S. O., et al, 2019 [24]	1- الشبكة العصبية الاصطناعية التلافيفية CNN 2- الشبكة العصبية التراجعية الاصطناعية RNN	تم تطبيق الشبكة العصبية التلافيفية CNN في التعرف علي فعاليات الإنسان وكذلك الشبكة العصبية التراجعية الاصطناعية RNN	أظهر البحث ان استخدام شبكة CNN لها فائدة كبيرة للتعرف علي فعاليات الإنسان افضل من شبكة RNN	اختلاف البحوث وطرق استخدامها للعديد من الخوارزميات وبنسب مختلفة	98%
Hayashi, T, et al, 2008 [27]	الشبكة العصبية العميقة deep neural networks (DNNs)	تم تطوير الهاتف الذكي لاداء مهام مراقبة وتسجيل الأنشطة اليومية ل 19 شخص, وتحويلها لقاعدة بيانات	استخدام الوسائط المتعددة بما في ذلك الصوت البيئي وإشارات	مقتصر فقط على الأنشطة اليومية الداخلية ولم يتم توسيعه ليشمل	95%

	الانشطة في الهواء الطلق.	التسريع ثلاثي المحاور DNN له دور فعال في تحسين الاداء	تتكون من اشارات صوتية بيئية.		
95.5%	اظهرت التجارب بان اداء RNNs لها اداء افضل من الطرق التقليدية وهي SVMs, Naïve Bayes, HMMs, Hidden Semi-Markov Models, and Conditional Random Fields (CRFs)	الشبكات العصبية الاصطناعية لها القدرة على التعامل مع البيانات غير المتوازنة بصورة جيدة, وامكانية الكشف عن الاختلاف	تم استخدام ثلاث شبكات عصبية اصطناعية وطرق التقليديه في التعرف علي فعاليات الانسان	1-ثلاث شبكات عصبية اصطناعية 2-الطرق التقليدية SVMs, Naïve Bayes, HMMs, Hidden Semi-Markov Models, and Conditional Random Fields (CRFs)	Arifoglu, D., et al, [25], 2017
91.15%	لم يتطرق لانشطة عديدة منها النوم او ركوب الدراجات, ولم يتوسع ليشمل العديد من	تم الجمع بين افضل ثلاث مصنقات, وبين ان طريقة متوسط الاحتمالات هي الافضل	تم استخدام مقياس تسارع ثلاثي المحاور, للتعرف على نشاطات مختلفة باستخدام الهاتف الذكي سواء اكان	Digital low-pass filter.	Bayat, A., et al [30], 2014

	الفئات العمرية.	في التعرف على النشاط متفوقا بذلك على جميع الطرق الاخرى.	في اليد او في جيب البنطال.		
%89	هناك حاجة لمزيد من الاختبارات وكذلك تطوير نظام يركز على الوقاية الكشف المبكر عن الحالات الصحية	النتائج التي تم تحقيقها تعتبر مرضية بالنسبة لأغراض المراقبة	تم تطبيق نظام لمراقبة المريض بالاعتماد على BSN القابلة للارتداء, وتم اختباره على عدد من المتطوعين خلال ايدائهم لعدد من الانشطة اليومية الاكثر شيوعا والتي تحتوي على مستويات متنوعة من الحركة و نشاط القلب.	BSN	Kantoch, E., et,al, [23] 2012
%91.1	لم يوفر معالجة مركزية للبيانات ولهذا فان مراقبة التحركات البشرية تتم بصورة لامركزية ولذلك يتطلب برنامج	مصادقية طريقه-K Nearest Neighbour تفتح المجال لتوفر فرص جديدة لتطوير تطبيقات جديدة وبتكلفة	الهدف من استخدام طريقه K-Nearest Neighbour هو التحقق من السعة الحالية للهواتف المحمولة لتمكنها من تنفيذ خوارزميات التعرف وتمييز	K-Nearest Neighbour	Brezmes,T. et al, 2009 [41] ,

	اضافي لكي يسجل ويبلغ عن التغييرات والتحركات البشرية	متخفضة نوعا ما.	الانماط اللازمة لتصنيف الحركات البشرية.		
97.7%	النموذج معقدا ويحتاج لتوفر العديد من الموارد الحاسوبية في الهاتف المحمول.	من اجل تقليل حجم النموذج المستخدم في هذه الطريقة, تم اجراء تقييم لكل ميزة من المميزات المستخدمة, وقد تبين انه من الممكن قطع وتحديد الميزة المستخدمة ببعد بين 22 الى 8 للحصول على نموذج اصغر.	منهجيته الطريقه هو بتميز الانشطة البدنية للاشخاص عندما يقومون بوضع الهاتف المحمول بالقرب من منطقة الحوض. باستخدام Decision Tree, Naive Bayes, Random Forest, Logistics Regression, RBF Network, Support Vector Machine	Decision Tree, Naive Bayes, Random Forest, Logistics Regression, RBF Network, Support Vector Machine	Sun, L., et al., [42] , 2011
90%	لاستطيع الطرق التقليديه في التعرف علي النشاط البشري عندما	جيده في التعرف علي النشاط البشري	استخدام اربع خوارزميات في التعرف علي النشاط البشري	اربع انواع من الخورزميات التقليدية (RF, NB, KNN, SVM)	Nhac,L., at el, 2018 [28]

	تكون البيانات غير متكامله				
94.6%	جيد في التعرف علي النشاط البشري لكنها اقل كفاءه من شبكات التعلم العميق مثل CNN,RNN	استخدام الشبكات العصبية Multi-layer perceptron ((MLP و Logistic Regression كفاءه في التعرف علي النشاط البشري	تطوير مجموعة من قواعد البيانات الخاصة التي جمعت باستخدام اجهزة الهواتف الذكية لتتميز النشاط البشري باستخدام الشبكات العصبية Multi-layer perceptron ((MLP و Logistic Regression	الشبكات العصبية Multi-layer perceptron ((MLP و Logistic Regression	Kwapisz,J.R. et al 2011 [29]

وبهذا نستخلص بان خوارزميات التعلم الالي تمتاز بانها خوارزميات خطية, حيث انه بالامكان تمثيلها بواسطة عقدة واحدة فقط تقوم بتحويل المدخلات خطيا الى مخرجات. سابقا أطلق على التعلم الالي بالشبكة العصبية الاصطناعية, والتي تمتاز باستخدامها عدة عقد تنظم على شكل الشبكات العصبية لتمثيل كيفية عمل العقل البشري. وكلما زادت عدد العقد والطبقات بالشبكات العصبية, زادت قدرات التعلم الخاصة بها[31].

على الرغم من استمرارية استخدام مصطلح الشبكات العصبية, فان شبكات التعلم الالي اليوم تمثل تدفق المعلومات عبر العقد والتي تشبه كيفية تدفق المعلومات الى الدماغ البشري عبر الخلايا العصبية, وتميل الابحاث الى استخدام التعلم الالي بديلا عن التعلم التقليدي. ووفقا للعديد من البحوث التي تمت دراستها, فان خوارزميات التعلم الالي ظهر بين عام 2014 الى عام 2018, ولكنه بعد عام 2014 اصبح رائجا استخدام خوارزميات التعلم الالي اكثر من استخدام الخوارزميات التقليدية في تمييز النشاط البشري[24].

مراقبة التحركات البشرية يمكن بسهولة تصويرها واستخدامها للعديد من الاغراض والتطبيقات المستقبلية. حيث قدم هذا البحث نظام تصنيف لبعض الحركات البشرية الاساسية في الوقت الحقيقي باستخدام الهاتف المحمول مزود بقياس متسارع. وقد حققت هذه الدراسة الهدف المطلوب منها وهو قياس السعة الحالية للهواتف المحمولة لتنفيذ خوارزميات تمييز الانماط في الوقت الحقيقي لتصنيف وتمييز التحركات البشرية. لم يتم توفير معالجة مركزية للبيانات ولهذا فان مراقبة التحركات البشرية تتم بصورة لامركزية ولذلك يتطلب برنامج اضافي لكي يسجل ويبلغ عن التغييرات والتحركات البشرية, مصادقية هذا النهج تفتح مجال جديدا لتطوير تطبيقات جديدة وبتكلفة منخفضة[41]

القدرة المميزة للاستشعار التي تمتاز بها الهواتف الذكية توفر فرصة فريدة لكشف والمراقبة المستمرة للتحركات البشرية, ومع ذلك, تطبيقات الهواتف الذكية يجب ان تمتثل لاستخدام واعدات الانسان بالاضافة الى التقاط اللحظة المناسبة لتساعد على تمييز النشاط البشري, والتي من المحتمل ان تسبب تباينات واختلافات كبيرة. نتيجة لذلك, قد يكون النموذج معقدا ويحتاج لتوفر العديد من الموارد الحاسوبية في الهاتف المحمول. يتم تمييز النشاط البشري عند وضع الهاتف المحمول في الجيب بالقرب من منطقة الحوض. وقد اظهرت النتائج ان دقة التمييز قد تصل الى 97.7%, من اجل تقليل حجم النموذج المستخدم في هذه الطريقة, تم اجراء تقييم لكل ميزة من المميزات المستخدمة, وقد تبين انه من الممكن قطع وتحديد الميزة المستخدمة بعدد بين 22 الى 8 للحصول على نموذج اصغر [42].

6- القضايا والتحديات

هناك الكثير من التحديات والمعوقات التي تواجه مصممي انظمه التعرف على النشاط البشري منها استخدام اجهزة الاستشعار المختلفة لجمع البيانات الاولية للتعرف على الانشطة, و هناك ثلاث انواع من اجهزة الاستشعار: مستشعرات الفيديو, اجهزة الاستشعار البيئية, واجهزة الاستشعار القابلة للارتداء [32]. وتعتبر الكاميرا اجهزة استشعار فيديو تحدد وتثببت باماكن خاصة. ولكاميرات RGB تركيزا اقل بالنسبة لباحث ال HAR, ربما بسبب تقييدها بالتقاط الصور وحركة الانسان في البية ثلاثية الابعاد. وكذلك التعرف على الشخص وتمييزه عن بيئته يتطلب محددات اكثر بسبب ان العملية تحتاج لمعالجة الية عالية. لهذا تتاثر جودة نظام تمييز النشاط البشري بالوقت الحقيقي. [33]

كما ان من المعوقات التي تواجهها المستشعرات القابلة للارتداء هي التقييد والانسداد عند استخدام كاميرا ال RGB. وان العيب الاساسي للمستشعرات القابلة للارتداء هو دقة التعرف, وذلك بسبب ان نظام تمييز النشاط البشري الذي يعتمد على المستشعرات القابلة للارتداء يحتاج لعدة مميزات منها امكانية وضع المستشعرات بالموقع المطلوب بالاضافة الى توزيع هذه المستشعرات على اجزاء الجسم المختلفة, فقد يسبب ذلك العديد من المتاعب, ويعتبر غير مريح للمستخدمين. حيث ان اجهزة الاستشعار القابلة للارتداء لتمييز النشاط البشري لايمكن ان تكون فعالة فقد ينسى الشخص استخدام المستشعر الخاص به. [34]

تمتاز تحديد موقع المستشعر بالنسبة للمستشعرات القابلة للارتداء او مستشعرات الهواتف الذكية بالحساسية الشديدة لتأثيرها الكبير على دقة المعلومات. تعتمد قراءة البيانات الاولية لمقاييس التسارع الموجودة في الهواتف الذكية او المستشعرات القابلة للارتداء على موضع المستشعر او اتجاهه على جسم الانسان. على سبيل المثال تختلف قراءة البيانات المتحركة تماما عندما يمشي الانسان والهاتف الذكي في يده او في جيبه. لذلك واجه العديد من الباحثين هذه المشكلة في محاولاتهم لايجاد الحل الامثل [35,39].

في حالة التعلم التقليدي, يجب استخلاص المميزات من بيانات المستشعر الاولية من قبل اي خبير بهذا المجال من اجل تقليل تعقيد البيانات وكذلك جعل الانماط اكثر وضوحا لخوارزمية التعلم. اما في التعلم الالي فله ميزة اساسية وهي امكانيته في استخراج المميزات عالية المستوى من البيانات بطريقة تدريجية ولهذا ليس هناك حاجة للخبرة الميدانية عند استخلاص المميزات. فيما يتعلق بنهج حل المشكلات, تقسم تقنيات التعلم الالي المشكلة الى اجزاء مختلفة ليتم حلها اولا ثم يتم جمع النتائج في المرحلة النهائية بينما يهدف التعلم الالي لحل المشكلة من البداية الى النهاية. كمثال الى ذلك, بالنسبة لمشكلة الكشف عن كائنات متعددة فان تقنيات التعلم الالي مثل نظام Yolov2 تاخذ الصورة كمدخل وتوفر الموقع واسم الكائنات عند الاخراج. [40]. من ناحية اخرى فبالنسبة لخوارزميات التعلم الالي الجانبية الاخرى مثل SVM, يلزم وجود خوارزمية للكشف عن الصندوق المحيط اولا لتحديد جميع الكائنات الممكنة للحصول على كائن معين كمدخل لخوارزمية التعلم من اجل تمييز الكائنات المتعلقة به.

لتقنيات التعلم الآلي متطلبات محددة ليتم تطبيقها وهي توفر الآلات المتطورة وهو عكس ما موجود بخوارزميات التعلم التقليدي الذي لا يحتاج لذلك، الجزء المهم في تنفيذ خوارزميات التعلم الآلي هو أنها تستغرق وقتا طويلا بسبب وجود عددا كبيرا من العوامل، على سبيل المثال، تستغرق خوارزمية Popular Deep Residual Networks حوالي اسبوعين للتدريب تماما من الصفر، بينما تستغرق تدريب خوارزمية التعلم الآلي التقليدية مثل KNN بضع ثوان الى بضع ساعات. في مرحلة الاختبار يكون الامر معاكسا تماما. تستغرق خوارزمية التعلم الآلي وقتا اقل لتعمل في وقت الاختبار .

7- تقييم اداء نظام التعرف علي النشاط البشري

يتم تقييم خوارزميات انظمه التعرف علي النشاط البشري في الغالب من خلال التحليل الإحصائي للنماذج باستخدام البيانات التجريبية المتاحة. الطريقة الأكثر شيوعًا هي مصفوفة الارتباك (confusion matrix) التي تسمح بتمثيل أداء الخوارزمية من خلال تحديد أنواع الأخطاء بوضوح (الإيجابيات والسلبيات الخاطئة) والعينات المتوقعة بشكل صحيح على بيانات الاختبار. منه ، يمكن أيضًا استخراج مقاييس مختلفة مثل دقة النموذج والحساسية والدقة بالإضافة إلى ذلك ، يمكن أن تدعم المؤشرات النوعية المقارنة الأخرى ، مثل عدد الأنشطة المتاحة وسرعة التنبؤ واستهلاك الذاكرة ، ولتقييم الاداء يتم أخذ هذه القيم بافتراض أن الفئة أ هي فئة الاهتمام أو الحالة الإيجابية. [17,16]

- الإيجابيات الحقيقية (TP): عينات فعلية للفئة A تم توقعها بشكل صحيح كفئة أ
 - السلبيات الحقيقية (TN): العينات الفعلية للفئة ب تم التنبؤ بها بشكل صحيح كفئة ب
 - الإيجابيات الكاذبة (FP): عينات فعلية من الفئة ب تم توقعها بشكل غير صحيح كفئة أ
 - السلبيات الكاذبة (FN): العينات الفعلية للفئة أ تم توقعها بشكل غير صحيح كفئة ب
- يمكن الحصول على الدقة كنسبة من النتائج الحقيقية (TP و TN) بالمعادلة التالية [16]:

$$\text{الدقة} = (TP + TN) / (TP + FP + FN + TN) \dots\dots\dots (1)$$

8- الاستنتاجات

يستعرض هذا البحث احدث التقنيات في التعرف وتمييز النشاط البشري، والتي لها دور كبير في تمييز والتقاط حركة كل جزء من جسم الانسان ثم نقلها لاحدى محركات البحث لتميزها وتحليلها وتحديد نوعها، تم ذكر وتصنيف العديد من اجهزة الاستشعار المستخدمة للتمييز منها اجهزة استشعار الهوائيات الذكية او اجهزة الاستشعار القابلة للارتداء كاميرا ال RGB. والتي لديها عدة استخدامات منها تمييز الحركة او قراءة الخصائص الحيوية للجسم او تحديد موقع الشخص، كما تم ذكر الهيكل العام لنظام التعرف على النشاط البشري، علاوة على ذلك، تركز تلك الدراسات على التعرف على الأنشطة البشرية وطرق التصنيف المختلفة والمستخدم في عملية التمييز، تم مقارنة بحوث تتعلق بالأنشطة والأجهزة المستخدمة في تمييز النشاط البشري ونماذج التعلم وإيجابيات وسلبيات كل خوارزمية مستخدمة ومجموعة البيانات ودقة التعلم. وأخيرا، تمت مناقشة المميزات والتحديات لكل نوع، وقد اظهرت هذه البحوث بانه قد تم استخدام التعلم الآلي مؤخرا أكثر من التعلم التقليدي لانه يمتاز بانه اكثر دقة و تستغرق وقتا اقل عند عملية الاختبار، وقد اظهر ايضا بانه خوارزميه التعلم الآلي CNN هو المستخدم بالغالب.

8- شكر وتقدير Acknowledgement

يتقدم الباحث بالشكر والتقدير لكل من يساهم في تقييم البحث وتقديم النصائح والارشادات لاثراء موضوع الدراسة.

9- المصادر: References

- [1] Avci,A; Bosch, S.; Marin-Perianu, M.; Marin-Perianu, R.; and Havinga,P. “Activity recognition using inertial sensing for healthcare, wellbeing and sports applications: a survey,” *International Conference on Architecture of Computing Systems*, 2010.
- [2] Oikonomopoulos, A. and Pantic, M. “Human Activity Recognition Using Hierarchically-Mined Feature Constellations,” *9th International Symposium, ISVC 2013, Rethymnon, Crete, Greece, July 29-31, 2013. Proceedings, Part I* pp. 150–159, 2013.
- [3] Javan, R. M. and Levine, M. D. “Human activity recognition in videos using a single example,” *Image Vis. Comput.*, vol. 31, no. 11, pp. 864–876, Nov. 2013.
- [4] Yang, J.; Lee, J. and Choi, J. “Activity Recognition Based on RFID Object Usage for Smart Mobile Devices,” *J. Comput. Sci. Technol.*, vol. 26, no. 2, pp. 239–246, Mar. 2011.
- [5] Chen, L.; Wei, H. and Ferryman, J. “A survey of human motion analysis using depth imagery,” *Pattern Recognit. Lett.*, vol. 34, no. 15, pp. 1995–2006, Nov. 2013.
- [6] Ong, W.; Palafox, L. and Koseki, T. “Investigation of Feature Extraction for Unsupervised Learning in Human Activity Detection,” *Bull. Networking, Comput. Syst. Softw.*, vol. 2, no. 1, pp. 30–35, 2013.
- [7] Lara O. D. and Labrador, M. a. “A Survey on Human Activity Recognition using Wearable Sensors,” *IEEE Commun. Surv. Tutorials*, vol. 15, no. 3, pp. 1192–1209, Jan. 2013.
- [8] Chaaaraoui, A. A.; Padilla-López, J. R.; Climent-Pérez, P. and Flórez-Revuelta, F. “Evolutionary joint selection to improve human action recognition with RGB-D devices,” *Expert Syst. Appl.*, vol. 41, no. 3, pp. 786–794, Feb. 2014.
- [9] Ryoo, M. S. “Human activity prediction: Early recognition of ongoing activities from streaming videos,” in *2011 International Conference on Computer Vision*, 2011, no. Iccv, pp. 1036–1043.
- [10] Chen, L.; Nugent, C. D. and Wang, H. “A Knowledge-Driven Approach to Activity Recognition in Smart Homes,” *IEEE Trans. Knowl. Data Eng.*, vol. 24, no. 6, pp. 961–974, Jun. 2012.
- [11] González-Ortega, D.; Díaz-Pernas, F. J; Martínez-Zarzuola, M. and Antón-Rodríguez, M. “A Kinect-based system for cognitive rehabilitation exercises monitoring,” *Comput. Methods Programs Biomed.*, vol. 113, no. 2, pp. 620–31, Feb. 2014.
- [12] Alshurafa, N.; Xu, W.; Liu, J.; Huang, M.-C.; Mortazavi, B.; Roberts, C. and Sarrafzadeh, M. “Designing a Robust Activity Recognition Framework for Health and Exergaming using Wearable Sensors,” *IEEE J. Biomed. Heal. informatics*, no. c, pp. 1–11, Oct. 2013.
- [13] Paragliola, G. and Coronato, A. “Intelligent Monitoring of Stereotyped Motion Disorders in Case of Children with Autism,” *2013 9th Int. Conf. Intell. Environ.*, pp. 258–261, Jul. 2013
- [14] Stone, E. and Skubic, M. “Passive, In-Home Gait Measurement Using an Inexpensive Depth Camera: Initial Results,” in *Proceedings of the 6th International Conference on Pervasive Computing Technologies for Healthcare*, 2012, pp. 183–186.
- [15] Wang, S.; Zabir, S. and Leibe, B. “Lying Pose Recognition for Elderly Fall Detection,” in *Robotics: Science and Systems VII*, no. 1, H. Durrant-Whyte, N. Roy, and P. Abbeel, Eds. MIT Press, 2012, pp. 345–3
- [16] Luis, J and Ortiz, R. “ Smartphone Based Human Activity Recognition,” *Springer Theses*, 2014

- [17] Ong, Ch. A.; theng, L. B. "Human Activity Recognition: A Review", 2014 IEEE International Conference on Control System, Computing and Engineering, 28 - 30 November 2014, Penang, Malaysia
- [18] Bruno, F. Mastrogiovanni, A. Sgorbissa, T. and Vernazza, R. Z., " Human motion modeling and recognition: a computational approach," IEEE International Conference on Automation Science and Engineering, 2012
- [19] Chen, J.; Hoey, C.D.; Nugent, D.J. and Cook, Z. Yu, "Sensor-based activity recognition," IEEE Transactions on Systems, Man, and Cybernetics, Part C: Applications and Reviews 42, 790–808 (2012)
- [20] Lara, O.; and Labrador, M. " A survey on human activity recognition using wearable sensors," IEEE Commun. Surv. Tutorials 1, 1–18 (2012)
- [21] Tamas, V. "Human Behavior Recognition In Video Sequences," Technical University of CLUJ-NAPOCA, 2013
- [22] Smisek, J.; Jancosek, M. and Pajdla, T. "3D with Kinect," in 2011 IEEE International Conference on Computer Vision Workshops (ICCV Workshops), 2011, pp. 1154–1160.
- [23] Kantoch, E. and Augustyniak, P. "Human activity surveillance based on wearable body sensor network," in Computing in Cardiology (CinC), 2012, pp. 325 – 328.
- [24] Slim, S. O.; Atia, A.; Elfattah, M. and Mostafa, M. " Survey on Human Activity Recognition based on Acceleration Data," (IJACSA) International Journal of Advanced Computer Science and Applications, Vol. 10, No. 3, 2019
- [25] Arifoglu, D. and Bouchachia, A. "Activity Recognition and Abnormal Behaviour Detection with Recurrent Neural Networks". *Procedia Computer Science*, 110, pp.86-93, (2017).
- [26] Van Kasteren,T; Englebienne, G. and Kröse, B. J. A. "Human activity recognition from wireless sensor network data", *Benchmark and software. Activity Recognition in Pervasive Intelligent Environments*, pages 165–186, 2011.
- [27] Hayashi, T.; Nishida, M.; Kitaoka, N.; Toda, T. and Takeda,K. "Daily Activity Recognition with Large-Scaled Real-Life Recording Datasets Based on Deep Neural Network Using Multi-Modal Signals", *IEICE Transactions on Fundamentals of Electronics, Communications and Computer Sciences*, vol. 101, no. 1, pp. 199-210, 2018
- [28] Nhaç, L. and Nguyen, T.; Ngo, T.; Nguyen, T. and Nguyen,H. "Mobile Online Activity Recognition System Based on Smartphone Sensors". *Advances in Information and Communication Technology: Proceedings of the International Conference, ICTA*, pp. 357-366, 2017
- [29] Kwapisz, J.R.; Weiss, G.M. and Moore, S.A. "Activity recognition using cell phone accelerometers," *ACM SigKDD Explorations Newsletter*, vol.12, no.2, pp.74–82, 2011.
- [30] Bayat, A.; Pomplun, M. and Tran, D. A. "A study on human activity recognition using accelerometer data from smartphones," *Procedia Computer Science*, vol. 34, pp. 450–457, 2014.
- [31] Alsheikh, M.A.; Selim, A.; Niyato, D.; Doyle, L.; Lin, S. and Tan, H.-P. "Deep Activity Recognition Models with Triaxial Accelerometers," In *Proceedings of the AAAI Workshop: Artificial Intelligence Applied to Assistive Technologies and Smart Environments*, Phoenix, AZ, USA, 12 February 2016
- [32] Turaga, P. ; Chellappa, R. ; Subrahmanian, V. and Udrea, O. "Machine recognition of human activities: A survey," *IEEE Trans. Circuits Syst.Video Technol.*, vol. 18, no. 11, pp. 1473–1488, 2008.
- [33] Xia, L. ; Chen, C. and Aggarwal, J. K. "View invariant human action recognition using histograms of 3D joints," in 2012 IEEE Computer Society Conference on Computer Vision and Pattern Recognition Workshops, 2012, pp. 20–27.

- [34] Vo, Q. V.; Lee, G. and Choi, D. “Fall Detection Based on Movement and Smart Phone Technology,” in 2012 IEEE RIVF International Conference on Computing & Communication Technologies, Research, Innovation, and Vision for the Future, 2012, pp. 1–4
- [35] Kaiming, H.; Xiangyu, Zh.; Shaoqing, R., and Jian, S.. “Identity Mappings in Deep Residual Networks,”. arXiv 2016.
- [36] Ouchi, K. and Doi, M. “Indoor-outdoor Activity Recognition by a Smartphone,” In Proceedings of the 2012 ACM Conference on Ubiquitous Computing, Pittsburgh, PA, USA, 5–8 September 2012; pp. 600–601.
- [37] Stewart, V.; Ferguson, S.; Peng, J.X. and Rafferty, K. “Practical automated activity recognition using standard smartphones,” In Proceedings of the IEEE International Conference on Pervasive Computing and Communications Workshops, Los Alamitos, CA, USA, 19–23 March 2012; pp. 229–234.
- [38] Gomes, J.; Krishnaswamy, S.; Gaber, M.; Sousa, P.; Menasalvas, E. and MARS: A “Personalized Mobile Activity Recognition System,” In Proceeding’s of the 2012 IEEE 13th International Conference on Mobile Data Management (MDM), Bengaluru, Karnataka, 23–26 July 2012; pp. 316–319.
- [39] Lane, N.D.; Mohammad, M.; Lin, M.; Yang, X.; Lu, H.; Ali, S.; Doryab, A.; Berke, E.; Choudhury, T. and Campbell, A. “Bewell: A smartphone application to monitor, model and promote wellbeing,” In Proceedings of the 5th International ICST Conference on Pervasive Computing Technologies for Healthcare, Dublin, Ireland, 23–26 May 2011; pp. 23– 26
- [40] Redmon, J. and Farhadi, A. “Better, faster, stronger. In: Computer Vision and Pattern Recognition,” (CVPR), 2017 IEEE Conference on, IEEE (2017) 6517– 6525.
- [41] T. Brezmes, J.-luis Gorricho, and J. Cotrina, “Activity Recognition from Accelerometer Data on a Mobile Phone,” Test, pp. 796-799, 2009.
- [42] L. Sun, D. Zhang, and N. Li, “Physical Activity Monitoring with Mobile Phones,” pp. 104-111, 2011.