

التعرف على أنشطة الجسم البشري وكشف السقوط من خلال الحساسات العطالية للهواتف الذكية

نعمة الله بلو *، محمد فاضل سكر **

* طالب دراسات عليا (ماجستير)، قسم الذكاء الصناعي، كلية الهندسة المعلوماتية، جامعة حلب

** قسم الذكاء الصناعي، كلية الهندسة المعلوماتية، جامعة حلب

الملخص

أصبحت الحساسات العطالية (حساس التسارع، حساس السرعة الزاوية) مكوناً مهماً تتضمنه جميع الهواتف الذكية تقريباً، وتستخدم فيها في العديد من التطبيقات. تم في هذا البحث تسجيل مجموعة بيانات من حساس التسارع وحساس السرعة الزاوية لهاتف ذكي حمّله 10 متطوعين أثناء قيامهم بـ 7 أنشطة، 6 من الحركات الاعتيادية اليومية بالإضافة إلى محاكاة السقوط. قام المتطوعون بتنفيذ كل من الأنشطة عدة مرات. تم تصميم وتدريب واختبار نظام للتعرف على أنشطة الجسم البشري وكشف السقوط من خلال البيانات المسجلة. اعتمد نظام التعرف على تقنية لإلغاء أثر تغير اتجاه الهاتف أثناء حمّله، واعتمد في استخراج السمات على السمات الإحصائية، واستخدم من أجل التصنيف مصنف معدّل عن آلة شعاع الدعم متعددة الأصناف Multi class SVM من النوع (One vs All، 1 مقابل الكل). تم الوصول إلى دقة تصنيف 92.52، وأشار اختبار إشارات الرتب لويلكوكسون عند مستوى معنوية 0.05 إلى تفوق المصنف المقترح على مصنف KNN وعلى مصنف آلة شعاع الدعم متعدد الأصناف التقليدي.

الكلمات المفتاحية: تعلم الآلة، آلة شعاع الدعم، الخوارزمية الجينية، الحساسات العطالية، التعرف على الأنشطة البشرية، الهاتف الذكي.

Human Activity Recognition and Fall Detection Using Inertia Sensors of Mobile Phone

Abstract

Inertial sensors (accelerometers, gyroscopes) became important components included in approximately all smart phones, and used in many applications. In this work, a dataset has been recorded from an accelerometer and a gyroscope of a smart phone carried by 10 volunteers while executing 7 actions, 6 normal daily actions beside of simulation of fall. Volunteers have executed every action many times. An intelligent system for human action recognition was designed, trained and tested using recorded data. The recognition system depended on a mechanism to nullify the effect of change in smartphone orientation while it is carried, and in feature extraction it depended on statistical features, and for classification it used a modified multi class SVM of type (1 VS all). A 92.52% classification accuracy was accomplished, and Wilcoxon signed rank test showed that the proposed classifier significantly outperforms kNN and traditional multiclass SVM at significance level of 0.05.

Keywords: Machine learning, Support vector machine, SVM, Genetic algorithm, GA, Inertia sensors, Human activity recognition, HAR, Smart phone.

1- المقدمة:

باتت أنظمة التعرف على النشاط الحركي البشري جزءاً من العديد من الأنشطة اليومية [1]. يمكن لتطبيقات مثل Google Fit [2] أو Apple Health [3] اكتشاف بعض الأنشطة مثل المشي والجري التي تستخدم في هذه التطبيقات في مقاييس الصحة واللياقة البدنية، كما تم إضافة ميزة كشف السقوط إلى الإصدار الرابع من ساعات Apple Watch [4] الذي تم طرحه في شهر أيلول من عام 2018. وتم تطوير العديد من تطبيقات كشف السقوط التي تعمل على أنظمة Android و iOS مثل RightMinder [5]. استخدمت تقنيات الرؤية البصرية والليزرية (الرؤية بالعمق) في بعض الأجهزة مثل Microsoft Kinect [6] وكاميرات Intel RealSense [7] كطريقة حديثة للتفاعل بين الإنسان والحاسب وفي تطبيقات الواقع الافتراضي المستخدمة بكثرة في الألعاب. واستخدمت تسجيلات الفيديو لأشخاص أثناء قيامهم بالمشي للحصول على بصمة للتعرف على الأشخاص للاستفادة منها في عمليات المصادقة [8].

مع التطور المستمر للأنظمة الكهروميكانيكية الدقيقة (MEMS)، أصبحت وحدات القياس العطالي (IMUs) Inertial Measurement Units المستخدمة لقياس التسارع والسرعة الزاوية أصغر حجماً. يمكن من خلال هذه الأجهزة إجراء تتبع الحركة في البيئة الحية الواقعية دون الحاجة لوجود أجهزة مراقبة مثبتة في مكان المراقبة.

أصبحت خوارزميات التعرف على أنشطة الجسم البشري التي تعتمد على تطبيق تقنيات التعلم الآلي باستخدام البيانات التي تم جمعها من الأجهزة القابلة للارتداء [9] بديلاً مناسباً لخوارزميات الكشف عن النشاط بالاعتماد على الرؤية كتلك المستخدمة في [10] و [11]. إن استخدام أجهزة الاستشعار القابلة للارتداء يعد بديلاً أسهل استخداماً وأكثر دقة وتوافرية وأكثر مراعاة لقضايا الخصوصية مقارنة بالأنظمة القائمة على الرؤية [9]. تستفيد بعض أنظمة المراقبة الصحية من أنظمة التعرف على الأنشطة البشرية باستخدام الأجهزة القابلة للارتداء من خلال تسجيل الأنشطة لإجراء المراقبة عن بعد والمراقبة على المدى الطويل وتسهيل الوصول إلى معلومات نشاط المريض [12] و [13]. توفر هذه الأجهزة معلومات قيمة حول أنشطة المريض في بيئة عمله ومعيشتة مما يسهل تقديم المساعدة في علاج العديد من الأمراض [14] حيث تعتبر هذه

المعلومات أفضل من تلك التي يتم الحصول عليها في العيادة أو المختبر، وحول مدى تنفيذ بعض التوصيات الطبية الشخصية [14].

يعتبر حساس التسارع من أكثر الحساسات استخداماً في الأبحاث المتعلقة بالتعرف على الأنشطة البشرية وكشف السقوط، يليه حساس السرعة الزاوية، وللحصول على نتائج أفضل يمكن استخدام كلا الحساسين معاً [15]، وقد لوحظ الميل في الأبحاث الأحدث إلى الاعتماد على الحساسات العطالية وأجهزة التصوير بالعمق بشكل أكبر من الاعتماد على التصوير الضوئي [15]. تتضمن جميع الهواتف الذكية اليوم حساسات تسارع كما تتضمن معظمها حساسات جيروسكوب لذلك ظهرت الكثير من الأبحاث التي تركز على تطوير تقنيات وخوارزميات التعرف على حركات الجسم البشري من خلال الحساسات العطالية للهواتف الذكية باعتبار هذه الهواتف تتضمن حساسات عطالية، وتتضمن معالجات قويا يمكن من تشغيل خوارزميات التعرف عليه، وفي نفس الوقت تتضمن العديد من وسائل الاتصال التي يمكن استخدامها للتبليغ عن حالة السقوط، كما أن المستخدم معتاد على حمل الهاتف عند وجوده خارج المنزل، ومعتاد على شحنه بشكل متكرر وبالتالي لا يتطلب نظام التعرف أي تجهيزات إضافية.

قدم [16] مجموعة البيانات sisfall التي تضمن تسجيلات لحساس تسارع مثبت على الخصر لـ 38 متطوعاً نفذوا 19 من الحركات اليومية بالإضافة إلى 15 نوعاً من السقوط. وقدم [17] مجموعة البيانات UniMiB SHAR التي تضمنت تسجيلات لحساس التسارع لهاتف ذكي وذلك لـ 30 متطوعاً نفذوا 9 من الأنشطة اليومية و 8 من حركات السقوط. بينما اعتمد [18] في مجموعة البيانات MobiFall على حساسي التسارع والسرعة الزاوية للهاتف المحمول وتضمنت المجموعة تسجيلات للحركات اليومية والسقوط نفذها 24 متطوعاً.

قدم [19] نظاماً لكشف السقوط أثناء الحركات اليومية كالمشي والجلوس والهولة حيث يعمل النظام على مرحلتين الأولى تتضمن مصنف متعدد الصفوف لتحديد نوع السقوط وفي المرحلة الثانية يتم اتخاذ القرار بناء على النتائج التي تم توقعها في المرحلة الأولى وتم التوصل إلى دقة 95.65%. توصل [20] إلى دقة 89% في

تصنيف الحركات اليومية وكشف السقوط عند استخدام مصنف آلة شعاع الدعم متعدد الأصناف Multi class SVM ونسبة تدريب 70%. في حين توصل [21] إلى دقة 91.76% في التعرف على الأنشطة اليومية وذلك باستخدام نموذج ماركوف المخفي Hidden Markov Model (HMM) وقسم البيانات إلى مقاطع بطول 2.56 sec واعتمد نسبة تدريب 70%. في [22] تم الوصول إلى دقة 93.8 وذلك في تصنيف 8 من الأنشطة اليومية وذلك باستخدام الشبكات العصبية الالتفافية ذات نواة الالتفافية معدلة وبالاعتماد على حساس التسارع. في حين تم في [23] الاعتماد على الشبكات العصبية الالتفافية CNN والوصول إلى دقة 95.75% في تصنيف الحركات اليومية. كما تم في [24] الوصول إلى دقة 95% في تصنيف الحركات اليومية وكشف السقوط بالاعتماد على الشبكات العصبية التكرارية العميقة Deep recurrent neural network (DRNN).

من الملاحظ أن الأبحاث ومجموعات البيانات السابقة تعتمد على حساسات مثبتة على الجسم في مكان محدد، أو على هاتف ذكي مثبت على الجسم أو محمول بطريقة محددة واتجاه محدد. يقدم هذا البحث مجموعة بيانات تتضمن تسجيلات للحساسات العطالية لهاتف ذكي موضوع بالحبيب الأيمن أو الأيسر دون تقييد المتطوعين باتجاه الهاتف وهو في الجيب. كما يطبق البحث تقنية تصنيف هجينة تعتمد على تعديل مصنف آلة شعاع الدعم التقليدي متعدد الصفوف Multi class SVM وتحسين بارامترات المصنف المعدل باستخدام الخوارزمية الجينية. تتناول الفقرات التالية معلومات حول مجموعة البيانات المستحصلة، كما تتضمن شرحاً لمراحل عمل المصنف المستخدم، والنتائج التي تم الحصول عليها ومقارنتها مع نتائج المصنفات الأخرى.

2- مجموعة البيانات والحساسات المستخدمة:

من أجل تسجيل البيانات تم استخدام هاتف من النوع Samsung S4 (i337) الذي يعمل بنظام Android 5.0، يتضمن الجهاز وحدة قياس عطالي من نوع STMicroelectronics k330، وتتضمن الوحدة حساس تسارع وحساس سرعة زاوية، وتم التسجيل لقيم كلا الحساسين بتردد 100Hz. قام بتنفيذ الحركات 10 متطوعين نفذ كل منهم 6 من الحركات اليومية بالإضافة إلى محاكاة عملية السقوط. تم تنفيذ كل

واحدة من الحركات عدة مرات مع مراعاة التنوع من خلال تنفيذ كل حركة بعدة سرعات بحيث يحاكي كل متطوع في كل حركة كل السرعات المختلفة التي يمكن ان يقوم بها في تصرفاته اليومية. أما بالنسبة للسقوط فقد تم تنفيذ أربعة أنواع من السقوط (أثناء المشي، أثناء الجري، أثناء الوقوف، أثناء المشي إلى الخلف) وتم تنفيذ كل نوع مرتين من قبل كل متطوع. يمثل الجدول (1) جميع الحركات المتضمنة في مجموعة البيانات وتتبعاتها ومدة التسجيل لكل منها.


الجدول (1) - الحركات المتضمنة في مجموعة البيانات

رقم الحركة	الحركة	عدد مرات التسجيل	مدة التسجيل (ثانية)
1	المشي (بطيء، متوسط، سريع)	60	581
2	الجري (بطيء، متوسط، سريع)	60	370
3	صعود الدرج (بطيء، متوسط، سريع)	60	430
4	نزول الدرج (بطيء، متوسط، سريع)	60	400
5	الجلوس (بطيء، سريع)	40	61
6	القيام (بطيء، سريع)	40	62
7	السقوط (أثناء المشي، أثناء الجري، أثناء الوقوف، أثناء المشي للخلف)	80	56
	كل الحركات	400	1960

طُلب من كل متطوع وضع الهاتف أثناء تسجيل البيانات في جيبه دون تحديد الجيب الأيمن أو الأيسر ودون تحديد جهة الهاتف داخل الجيب.

تم إنشاء تطبيق يعمل على نظام Android من أجل تسجيل البيانات، الشكل (1). يدخل المتطوع رقمه (كل متطوع له رقم يميزه)، ورقم الحركة التي يريد أن يقوم بها (كما هو محدد في الجدول 1) ثم يضغط على زر البدء ثم يضع الهاتف في جيبه. بعد ذلك على المتطوع الوقوف بشكل ساكن لمدة ثانيتين على الأقل (ويمكن الوقوف لمدة أطول) ثم يبدأ بعد فترة الوقوف هذه بتنفيذ الحركة مباشرة، كما أنه بعد تنفيذ الحركة مباشرة يقوم أيضا بالوقوف بشكل ساكن لمدة ثانيتين على الأقل. يقوم تطبيق التسجيل باكتشاف فترة السكون الأول واقتطاعها واقتطاع ما قبلها من التسجيل، كما يقوم باكتشاف فترة السكون الثانية واقتطاعها واقتطاع ما بعدها من التسجيل. تمنع التقنية

السابقة من دخول القيم المسجلة أثناء وضع الهاتف في الجيب أو إخراجها منه ضمن التسجيل الذي يقوم التطبيق بحفظه في ملف نصي على ذاكرة الهاتف.




الشكل (1) - واجهة التطبيق المستخدم في تسجيل البيانات

لا يمكن استخدام التقنية السابقة لاقتطاع تسجيلات عملية السقوط إذ لا يمكن للمتطوع الوقوف بشكل ساكن قبل السقوط لأن السقوط يكون أثناء المشي أو الجري، لذلك تم تصوير عملية السقوط واستخدام تسجيلات الفيديو لتحديد نقطة بداية السقوط في تسجيلات الحساسات وذلك من خلال برنامج يعمل على نظام Windows تم إنشاؤه لهذا الغرض، يقوم البرنامج بمزامنة الفيديو مع تسجيلات قيم الحساسات من خلال تحديد فترة الوقوف الساكن في تسجيلات الحساسات وتسجيلات الفيديو وذلك بمساعدة مستخدم البرنامج.

يدعم نظام التشغيل Android العديد من الحساسات حسب توفرها في الهاتف المستخدم وقد تم تسجيل قيم أربع حساسات هي: حساس التسارع، حساس السرعة الزاوية، حساس الجاذبية، حساس التسارع الخطي. وتضمن التسجيل ثلاث قيم لكل حساس للمحاور الثلاث المبينة بالشكل (2).


يمثل حساس التسارع مجموع قيمتي تسارع الجاذبية بالإضافة إلى التسارع الناتج عن حركة الجهاز وهي قيم التسارع التي يقرأها النظام مباشرة من حساس التسارع في

وحدة القياس العطالي المتضمنة في الجهاز. يستخدم نظام التشغيل Android تقنية تعتمد على مرشح تمرير الترددات المنخفضة لفصل تسارع الجاذبية عن التسارع الخطي الناتج عن الحركة وبالتالي فإن الحساسين الأخيرين برمجياً أي يقوم نظام التشغيل بحساب قيمها برمجياً من الحساسات الأخرى.



الشكل (2) - المحاور الإحداثية للهاتف المعتمدة في نظام التشغيل Android

يتم تسجيل قيم حساسات التسارع الثلاثة بـ $m.s^{-2}$ وقيم السرعة الزاوية بـ Radian/s. يمثل الشكل (3) بعض التسجيلات من مجموعة البيانات وهي القيم المطلقة لحساس السرعة الزاوية لأحد تسجيلات المشي في الأعلى يليها أحد تسجيلات الجري ثم أحد تسجيلات صعود الدرج ثم نزول الدرج.



الشكل (3)، بعض التسجيلات من مجموعة البيانات

3- استخراج السمات:

تم في مرحلة جمع البيانات مراعاة عدم تقييد المتطوعين بوضع الهاتف باتجاه محدد، لذلك فقد تم في مرحلة استخراج السمات إلغاء أثر تغير اتجاه الهاتف أثناء جمع البيانات وذلك من خلال الحصول على 4 إشارات من الإشارات التي تم تسجيلها وهذه الإشارات لا تختلف قيمها حسب اتجاه الهاتف وهي:

- القيمة المطلقة للتسارع الخطي، وهي الجذر التربيعي لمجموع مربعات مركبات شعاع التسارع الخطي

$$|Acc| = \sqrt{acc_x^2 + acc_y^2 + acc_z^2}$$

- القيمة المطلقة للسرعة الزاوية، وهي الجذر التربيعي لمجموع مربعات مركبات شعاع السرعة الزاوية

$$|Gyr| = \sqrt{gyr_x^2 + gyr_y^2 + gyr_z^2}$$

- قيمة مسقط شعاع التسارع الخطي على شعاع الجاذبية الأرضية، وهي قيمة جداء شعاع الجاذبية الأرضية مضروباً بشعاع التسارع الخطي، مقسومة على قيمة تسارع الجاذبية $g=9.8$.

$$Acc_earth = (acc * earth) / g$$

حيث acc هو شعاع التسارع الخطي، $earth$ هو شعاع الجاذبية الأرضية.
- القيمة المطلقة للمساكن الأفقية للتسارع الخطي وهي الجذر التربيعي لمربع القيمة المطلقة للتسارع الخطي مطروحاً منه مربع مسقط التسارع الخطي على محور الجاذبية:

$$Acc_horz = \sqrt{|acc|^2 - Acc_earth^2}$$

بعد حساب الإشارات الأربعة السابقة تم استخراج السمات منها. تم تقسيم الإشارات إلى نوافذ بعرض 2 sec وتداخل 1.5 sec ثم تم استخراج سمات إحصائية للنوافذ التي تم الحصول عليها حيث تم استخراج 3 سمات لكل إشارة من الإشارات الأربعة وهذه السمات هي:

- اللوغاريتم العشري للجذر التربيعي لمتوسط مربعات القيم:

$$\text{Log}_{10}(\text{Sqrt}(\text{Mean}(X^2)))$$

حيث X هو مصفوفة أحادية تتضمن قيم نافذة من إحدى الإشارات.

- اللوغاريتم العشري للانحراف المعياري للقيم:

$$\text{Log}_{10}(\text{Std.Dev}(X))$$

- طول المنحني الذي تمثله قيم النافذة.

وبالتالي تم استخراج ثلاث سمات إحصائية لكل واحدة من الإشارات الأربعة أي

تم استخراج 12 سمة لكل نافذة من النوافذ.

4- التصنيف:

يستخدم مصنف آلة شعاع الدعم متعدد الصفوف Multi class SVM من نوع (واحد مقابل الكل one VS all) مصنفات SVM ثنائية فرعية عددها هو عدد الأصناف المطلوب تصنيفها. يقوم المصنف الفرعي الأول بتحديد فيما إذا كان الدخل ينتمي إلى الصنف الأول أو لا، وهكذا بالنسبة لباقي المصنفات. يتم بعدئذ التصويت بين هذه المصنفات لاختيار الصنف الذي ينتمي له الدخل. لحل مشكلة عدم التعيين عند التصويت لاختيار الصنف، يتم التصويت عادة بناء على خرج النقاط scores للمصنفات الفرعية وهو عدد حقيقي، وليس على الخرج الثنائي مما يتيح إمكانية تصويت أدق عند اختيار الصنف الذي ينتمي له الدخل.

عند تدريب مصنفات ثنائية من النوع (1 مقابل الكل) لتصنيف البيانات قيد

الدراسة تم ملاحظة ما يلي:

- عند اختلاف نسبة الدخل من الصنف 1 في عينة التدريب، يتم الحصول على

مصنفات مختلفة في الدقة ويصعب تحديد النسبة المثالية من الصنف 1 للحصول على المصنف الأفضل ويختلف ذلك من صنف لآخر.

- عند استخدام مجموعة بيانات متوازنة (عدد الدخل من كل صنف متساو) فإن

نسبة الدخل من الصنف 1 في عينة التدريب ستكون قريبة من (1/عدد الأصناف) وهذه النسبة ليست النسبة المثلى التي تؤدي إلى الحصول على المصنف الثنائي الأفضل.

- عند استخدام عينة تدريب بحيث يكون فيها نسبة الدخل من الصنف 1 صغيرة يتم الحصول على مصنف يكون فيه عدد الأخطاء في تصنيف الدخل من الصنف 0 صغيراً وعدد الأخطاء في تصنيف الدخل من الصنف 1 كبيراً والعكس بالعكس.

إن الملاحظات السابقة تُحَفِّز على إنشاء أكثر من مصنف ثنائي لنفس الصنف بحيث يتم تدريب هذه المصنفات بعينات تدريب جزئية تختلف عن بعضها بنسبة الدخل من الصنف 1 فيها، ثم إيجاد تقنية التصويت المناسبة بين هذه المصنفات. تم تصميم مصنف يعتمد على استخدام الخوارزمية الجينية من أجل تحديد نسبة الدخل من الصنف 1 لكل مصنف من المصنفات الفرعية وأولوية هذه المصنفات في التصويت وقد أدى ذلك إلى الحصول على نتائج أفضل من المصنفات التقليدية كمصنف آلة شعاع الدعم متعدد الصفوف Multi class SVM ومصنف k.NN.

4-1- تدريب المصنفات الثنائية:

أ- اختيار عينة التدريب بناء على نسبة محددة من البيانات الكلية وبشكل عشوائي دون أي تحيز في اختيار نسبة كل من الأصناف في عينة التدريب وإنما يتم ذلك عشوائياً.

ب- لكل صنف من الأصناف السبعة يتم بناء 10 مصنفات ثنائية فرعية من نوع آلة شعاع الدعم بنواة خطية (Linear SVM) يتم تدريبها بعشر عينات جزئية يتم اختيارها من عينة التدريب المختارة في الخطوة السابقة بحيث تكون نسب الدخل من النوع 1 في العينات الجزئية هي: 0.05، 0.1، 0.2، 0.3، 0.4، 0.5، 0.6، 0.7، 0.8، 0.9 وبحيث يكون حجم كل منها أكبر ما يمكن وبالتالي يتم الحصول على 70 مصنفاً فرعياً. تم اختيار هذه النسب لتغطي طيفاً واسعاً من النسب الممكنة والتي سيتم فيما بعد اختيار بعضها كما توضح الفقرات التالية.

ت- يتم اختبار المصنفات التي تم بناؤها في الخطوة السابقة باستخدام عينة التدريب المختارة في الخطوة الأولى ويتم حفظ نتائج التصنيف لكل مصنف مع كل دخل من عينة التدريب.

4-2- تطبيق الخوارزمية الجينية لاختيار المصنفات وترتيبها:

يتم اختيار 15 أو 20 أو 25 مصنف فرعي أو حتى غير ذلك (عدد المصنفات الفرعية هو أحد بارامترات نظام التعرف) كما يتم اختيار الترتيب الذي يحدد أولوية هذه المصنفات في اتخاذ قرار التصنيف النهائي باستخدام الخوارزمية الجينية. وبهذا يكون لدينا مصنف متعدد يعتمد على عدد من المصنفات الثنائية الفرعية مرتبة ترتيباً جيداً في أولوية التصويت بحيث تعطي نتائج جيدة في اتخاذ قرار التصنيف النهائي.

4-2-1- بنية الكروموزوم:

يتم تخزين المصنفات الفرعية في مصفوفة (70x1). وبهذا تكون بنية الكروموزوم عبارة عن مصفوفة بطول 15 أو 20 أو 30 من الأعداد الصحيحة كل منها هو جين من جينات الكروموزوم حيث يمثل هذا الجين فهرساً أو رقم مصنف ثنائي فرعي حيث يمثل العدد الأول فهرس المصنف الفرعي ذا الأولوية الأعلى. وبهذا يحدد الكروموزوم المصنفات التي ستدخل في عملية التصنيف وأولوياتها.

4-2-2- تابع الملاءمة Fitness:

يعيد تابع الملاءمة دقة مجموعة المصنفات المرتبة الممثلة بالكروموزوم عند تصنيف عينة التدريب ويعتمد في ذلك على القيم المحسوبة مسبقاً في الخطوات من مرحلة التدريب حيث يفيد الاحتفاظ بتلك القيم في اختصار الوقت اللازم لتنفيذ الخوارزمية الجينية وذلك من خلال تقليل عدد المرات التي يتم فيها اختبار المصنفات الفرعية على عينة التدريب.

4-2-3- التصالب:

يتم إجراء التصالب بالاعتماد على قطع الأبوين عند نقطة أو نقطتين والحصول على ابنين من دمج الأبوين. على الرغم من أن التكرار في جينات الابن الناتج لا يؤدي إلى الحصول على حل غير مقبول إلا أن هذا التكرار يؤدي إلى الحصول على حلول غير فعالة لذلك تقوم عملية التصالب بمعالجة حالة التكرار في جينات الابن وذلك بحذف الجينات المكررة وإضافة جينات عشوائية بدلا منها في نهاية الكروموزوم.

4-2-4- الطفرة:

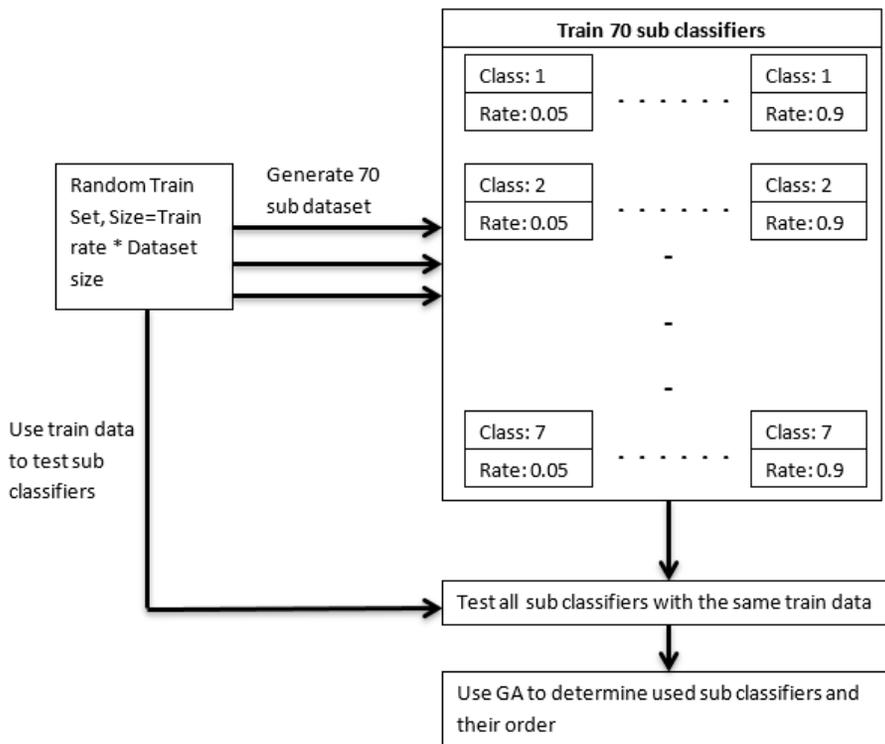
يختار تابع الطفرة بشكل عشوائي إحدى الطفرتين التاليتين لتطبيقها على جينين عشوائيين: الطفرة الأولى تقوم بتبديل قيمتي الجينين والثانية تقوم بعكس قيمة الجين الأول (أي إذا كان يشير إلى المصنف الأول فإنه سيشير إلى المصنف الأخير وهكذا) ووضع قيمة عشوائية في الجين الثاني.

4-2-5- البارامترات الجينية المستخدمة:

الجدول (2)، بارامترات الخوارزمية الجينية المستخدمة في تدريب النظام

25 مصنف فرعي	20 مصنف فرعي	15 مصنف فرعي	
3000	3000	3000	عدد الدورات
150	100	100	حجم المجتمع
3	3	3	عدد النخبة
0.7	0.7	0.7	نسبة التصالب
نقطتين	نقطتين	نقطة واحدة	نوع التصالب
0.1	0.1	0.1	نسبة الطفرة
Rank	Rank	Rolette	طريقة الاختيار

إن تدريب نظام التعرف المقترح يستغرق وقتاً أطول من بعض المصنفات التقليدية الأخرى خصوصاً مرحلة تطبيق الخوارزمية الجينية إلا أنه مقبول جداً حيث استغرق تدريب النظام بعينة تدريب حجمها 3000 للحصول على مصنف يحوي 25 مصنفاً فرعياً أقل من ثلاث دقائق على حاسب بمعالج Intel core i3 بسرعة 2.53GHz وباستخدام نواة واحدة. يمثل الشكل (3) مخططاً يوضح طريقة تدريب المصنف المقترح.



الشكل (4)، مخطط يوضح طريقة تدريب المصنف المقترح.

4-3- استخدام النظام:

يتكون النظام المدرب من عدد من المصنفات الثنائية الفرعية ومصنوفة تحدد أولوية هذه المصنفات في اتخاذ القرار النهائي. يتم استخدام النظام بتمرير الدخل إلى المصنفات الفرعية المستخدمة فقط ثم تحديد النتيجة النهائية لكل دخل بناء على مصنوفة الأولويات. استغرق التعرف على عينة دخل حجمها 3500 باستخدام مصنف يتكون من 25 مصنفاً فرعياً 740ms وذلك على نفس الحاسب المذكور في الفقرة السابقة.

5- تقييم أداء النظام:

تم إجراء 30 اختباراً باستخدام 30 عينة تدريب مختارة عشوائياً، 10 منها بحجم 50% من البيانات و 10 منها بحجم 60% من البيانات و 10 عينات بحجم 70% من البيانات. تم تدريب 5 مصنفات باستخدام العينات السابقة وهي: ثلاث مصنفات من النوع المقترح في هذا البحث يتضمن كل منها 15 أو 20 أو 25 مصنفاً فرعياً، ومصنف آلة شعاع الدعم متعدد الأصناف التقليدي من النوع (1 مقابل 1)، ومصنف

kNN. يبين الجدول (3) والجدول (4) والجدول (5) دقة تصنيف المصنفات الستة للبيانات المستخدمة عند تدريبها بعينات التدريب ذات الحجم 50% ثم العينات ذات الحجم 60% ثم العينات ذات الحجم 70% على الترتيب. ويبين الجدول (6) المتوسط والانحراف المعياري للدقة لكل واحد من المصنفات عند كل نسبة تدريب.

أشار اختبار إشارات الرتب لويلكوكسون عند مستوى معنوية 0.05 إلى تفوق كل من المصنفات من النوع المقترح على مصنف kNN وعلى مصنف آلة شعاع الدعم متعدد الأصناف التقليدي من النوع (1 مقابل 1).

الجدول (3)، دقة تصنيف المصنفات الخمسة للبيانات المستخدمة عند تدريبها بعينات تدريب بحجم 50%.

25 مصنف فرعي	20 مصنف فرعي	15 مصنف فرعي	SVM متعدد الأصناف	kNN	
89.57	89.34	88.88	86.31	80.39	1
90.09	89.01	89.16	86.4	79.54	2
90.02	89.53	89.09	86.75	80.78	3
90.36	89.8	88.28	86.24	79.95	4
89.99	89.21	88.57	85.74	80.78	5
90.01	89.46	89.21	86.06	80.23	6
89.78	89.25	88.58	85.53	79.12	7
90.19	89.31	89.04	86.04	80.56	8
90.27	89.63	88.82	85.88	80.11	9
90	89.48	88.57	85.6	80.64	10
90.03	89.4	88.82	86.06	80.21	mean
0.229	0.227	0.31	0.382	0.548	Std. dev.

الجدول (4)، دقة تصنيف المصنفات الخمسة للبيانات المستخدمة عند تدريبها بعينات تدريب بحجم 60%.

25 مصنف فرعي	20 مصنف فرعي	15 مصنف فرعي	SVM متعدد الأصناف	kNN	
91.28	91.39	90.55	88.56	86.39	1
91.17	91.38	90.78	87.94	86.12	2
90.82	91.15	90.62	87.87	86.75	3
90.81	90.79	90.29	88.2	86.81	4
90.96	91	90.55	87.57	86.49	5

التعرف على أنشطة الجسم البشري وكشف السقوط من خلال الحساسات العظالية للهواتف الذكية

90.98	91.05	90.62	88.2	86.77	6
91.16	90.89	90.76	88.19	86.63	7
91.03	90.89	90.82	87.92	87.08	8
91.26	91.21	90.9	87.62	86.88	9
90.88	90.71	90.42	88.1	86.24	10
91.04	91.05	90.63	88.02	86.62	mean
0.174	0.235	0.189	0.297	0.302	Std. dev.

الجدول (5)، دقة تصنيف المصنفات الخمسة للبيانات المستخدمة عند تدريبها ببيانات تدريب بحجم 70%.

25 مصنف فرعي	20 مصنف فرعي	15 مصنف فرعي	SVM متعدد الأصناف	kNN	
92.4	92.34	91.43	89.06	90.99	1
92.63	92.47	91.81	88.82	90.56	2
92.37	92.25	92.22	89.53	91.03	3
92.39	92.52	91.95	89.04	90.38	4
92.36	92.79	92.19	89.85	90.57	5
92.62	92.57	92.24	89.47	90.05	6
92.72	92.68	92.08	89.41	90.38	7
92.7	92.51	92.37	89.47	90.49	8
92.42	92.41	91.74	89.31	90.49	9
92.59	92.42	92.03	89.05	90.07	10
92.52	92.5	92.01	89.3	90.5	mean
0.145	0.158	0.282	0.306	0.324	Std. dev.

الجدول (6)، المتوسط والانحراف المعياري للدقة لكل من المصنفات عند نسب التدريب المختلفة.

25 مصنف فرعي	20 مصنف فرعي	15 مصنف فرعي	SVM متعدد الأصناف	kNN	حجم عينة التدريب
90.03	89.4	88.82	86.06	80.21	%50
0.229	0.227	0.31	0.382	0.548	
91.04	91.05	90.63	88.02	86.62	%60
0.174	0.235	0.189	0.297	0.302	
92.52	92.5	92.01	89.3	90.5	%70
0.145	0.158	0.282	0.306	0.324	

لا يمكن مقارنة النتائج الحالية مع نتائج بعض الدراسات السابقة لعدم تشابه ظروف الدراستين مثل [19] حيث ذُكرت نتائج التصنيف في كشف السقوط فقط دون تصنيف الحركات اليومية أي أن الدراسة استخدمت آلية لتصنيف البيانات إلى صنفين هما صنف السقوط وصنف الحركات اليومية (أو عدم السقوط). يوضح الجدول (7) مقارنة نتائج البحث الحالي مع نتائج بعض الأبحاث السابقة.

الجدول (7) - مقارنة نتائج البحث الحالي مع الأبحاث السابقة

النتيجة	التقنية	البحث
92.52%	مصنف معدل عن آلة شعاع الدعم، سمات إحصائية تراعي الاختلاف في اتجاه الهاتف	البحث الحالي
89%	آلة شعاع الدعم SVM	[20]
91.76%	نموذج ماركوف المخفي HMM	[21]
93.8%	الشبكات العصبية الالتفافية CNN	[22]
95.75%	الشبكات العصبية الالتفافية CNN	[23]
95%	الشبكات العصبية التكرارية العميقة DRNN	[24]

6- الخلاصة:

تم في هذا البحث استحصال مجموعة بيانات من حساسات تسارع وحساسات جيسكوب لهاتف ذكي وذلك أثناء تنفيذ 6 من الحركات اليومية بالإضافة إلى محاكاة السقوط. شارك في عملية جمع البيانات 10 متطوعين وتضمنت البيانات 400 تسجيل بطول إجمالي 1960 ثانية. لم يتم تقييد المتطوعين باتجاه محدد للهاتف أثناء التسجيل بخلاف مجموعات البيانات الأخرى. تم الحصول على أربع إشارات ألغى فيها تأثير اختلاف اتجاه الهاتف، وتم استخلاص سمات إحصائية منها. اعتمد نظام التصنيف على مصنف آلة شعاع الدعم متعدد الصفوف معدّل عن المصنف التقليدي وتم الوصول إلى دقة 92.52 عند التدريب بـ 70% من البيانات. أشارت الاختبارات الإحصائية إلى تفوق آلية التصنيف المستخدمة على المصنفات التقليدية عند مستوى معنوية 0.05 وذلك عند استخدام نفس البيانات ونفس الطريقة في استخراج السمات. كانت دقة التصنيف لنظام التعرف الذي تم تصميمه في هذا البحث أعلى من دقة التصنيف في الدراسات التي اعتمدت على تقنيات التصنيف التقليدية مثل آلة شعاع الدعم ونموذج ماركوف المخفي، لكنها لم تتفوق على نتائج الأبحاث التي اعتمدت على تقنيات التعلم العميق كالشبكات

العصبية الالتفافية والشبكات العصبية التكرارية العميقة، إلا أن البحث الحالي يتميز عن الأبحاث السابقة بعدم التقييد باتجاه محدد للهاتف.

7- الاقتراحات والأعمال المستقبلية:

توصل البحث إمكانية الحصول على نتائج جيدة مع عدم التقييد باتجاه الهاتف وتقوم نظام التصنيف المقترح على الأنظمة التقليدية الأخرى حتى ضمن هذا الشرط، وهذا يحفز على استخدام الإشارات الأربعة التي تم الحصول عليها مع تقنيات التعلم العميق لتحديد إمكانية الحصول على نتائج تضاهي النتائج الحالية دون التقييد باتجاه الهاتف.

المراجع

- [1] A. Wang, G. Chen, J. Yang, S. Zhao and C.-Y. Chang, "A Comparative Study on Human Activity Recognition Using Inertial Sensors in a Smartphone," *IEEE Sensors Journal*, vol. 16, no. 11, pp. 4566-4578, 2016.
- [2] Google, "Google Fit," 2020. [Online]. Available: <https://www.google.com/fit/>.
- [3] Apple, "Apple Health," [Online]. Available: <https://www.apple.com/ios/health/>.
- [4] Apple, "Apple Watch Series 4," [Online]. Available: <https://www.apple.com/apple-watch-series-4>.
- [5] C. L. Pty, "RightMinder – Fall Detection Application," [Online]. Available: <http://www.rightminder.com>.
- [6] Microsoft, "Microsoft Kinect," [Online]. Available: <https://developer.microsoft.com/en-us/windows/kinect/>.
- [7] Intel, "Intel Real Sense," [Online]. Available: <https://software.intel.com/realsense>.
- [8] L. Sudha and R. Bhavani, "Biometric Authorization System using Gait Biometry," *International Journal of Computer Science, Engineering and Applications (IJCEA)*, vol. 1, no. 4, 2011.
- [9] Lara, O.D. and Labrador, M.A., "A survey on human activity recognition using wearable sensors," *IEEE Communications Surveys & Tutorials*, p. 1192–1209, 2013.
- [10] Turaga, P., Chellappa, R., Subrahmanian, V.S. and Udreă. O., "Machine recognition of human activities: A survey," *IEEE Transactions on Circuits and Systems for Video Technology*, vol. 18, no. 1, p. 1473–1488, 2008.
- [11] R. A. Poppe, "Survey on vision-based human action recognition," *Image and Vision Computing*, vol. 28, no. 6, p. 976–990, 2010.
- [12] Hassanalieragh, M., Page, A., Soyata, T., Sharma, G., Aktas, M., Mateos, G, Kantarci, B. and Andreescu, S., "Health Monitoring and Management Using Internet-of-Things (IoT) Sensing with Cloud-based Processing: Opportunities and Challenges," *Proceedings of the IEEE International*

Conference on Services Computing (SCC), 2015.

- [13] A. Pantelopoulos, "A survey on wearable sensor-based systems for health monitoring and prognosis," *IEEE Transactions on Systems, Man, and Cybernetics, Part C (Applications and Reviews)*, vol. 40, no. 1, 2010.
- [14] A. Nazabal, García-Moreno, P., Artés-Rodríguez, A. and Ghahramani, Z., "Human Activity Recognition by Combining a Small Number of Classifiers," *IEEE Journal of Biomedical and Health Informatics*, vol. 20, no. 5, 2016.
- [15] R. Saini and V. Maan, "Human Activity and Gesture Recognition: A Review," in *International Conference on Emerging Trends in Communication, Control and Computing (ICONC3)*, Lakshmanarh, 2020.
- [16] A. Sucerquia, J. D. López and J. F. Vargas-Bonilla, "SisFall: A Fall and Movement Dataset," *Sensors*, vol. 17, no. 1, p. 198, 2017.
- [17] D. Micucci, M. Mobilio and P. Napoletano, "UniMiB SHAR: A Dataset for Human Activity Recognition Using Acceleration Data from Smartphones," *Applied Sciences*, vol. 7, no. 1101, 2017.
- [18] G. Vavoulas, M. Padiaditis, C. Chatzaki, E. Spanakis and M. Tsiknakis, "The mobifall dataset: Fall detection and classification with a smartphone," 2016.
- [19] John C. Dogan and Md Shafaeat Hossain, "A Novel Two-Step Fall Detection Method Using Smartphone Sensors," 2019.
- [20] D. Anguita, A. Ghio, X. Parra, X. Parra and J. L. Reyes-Ortiz, "A Public Domain Dataset for Human Activity Recognition Using Smartphones," in *21th European Symposium on Artificial Neural Networks, Computational Intelligence and Machine Learning*, 2013.
- [21] C. Ronao and S. Cho, "Human activity recognition using smartphone sensors with two-stage continuous hidden Markov models," in *e sensors with two-stage continuous hidden Markov (ICNC)*, 2014.
- [22] M. A. Alsheikh, A. Selim, D. Niyato, L. Doyle, L. Shaowei and H. P. Tan, "Deep Activity Recognition Models with Triaxial Accelerometers," in *The Workshops of the Thirtieth AAAI*, 2016.
- [23] C. Ronao and S. Cho, "Human activity recognition with smartphone sensors using deep learning neural networks," *Expert Systems with Applications*, vol. 59, pp. 235-244, 2016.

- [24] I. Masaya, I. Sozo and N. Takeshi, "Deep Recurrent Neural Network for Mobile Human Activity Recognition With High Throughput," *Artifitial Life Robotics Journal*, vol. 23, pp. 173-185, 2018.

