Enhancing Gait Recognition System Using Smartphone Sensors (IMU) and Deep Learning Techniques

Dr. Talal Hamoud*
Abeer Mohsin Saleh**

(Received 3 / 8 / 2024. Accepted 18 / 9 / 2024)

□ ABSTRACT □

In this article, person re-identification approach was developed based on structured data that was obtained from smartphone sensors, especially gyroscopes and accelerometers. The approach basically uses sensors measurements as gait features to identify the person. The data is structured in tables but converted to images with specific dimensions (n*m) where m is number of features (6: 3 gyroscopes components and 3 accelerometers components) and n the sample length; it refers to period of gait motion. The dataset was from OU-ISIR Biometric Database. The parameter n was chosen after many tries and best value was 128. The structured data is converted to images with dimensions (128*6) and then feed into developed deep learning model that basically uses deep learning layers (Convolution, Batch normalization, Memory units, Masking, Dropout, Permute and Pooling). The tuning process was processed on some parameters to get best values such as number of units in LSTM (Long Short-Term Memory), strides of convolution layers in the model and learning rate of learning process. In addition, parallel processing in the model was used to enhance the data features since the number of features is small, the final model showed high re-identification accuracy (98.23 %)

Keywords: Person re-identification, Gait features, Inertial sensor dataset, Deep learning model, Tuning parameters, Parallel processing

Copyright **:**Tishreen University journal-Syria, The authors retain the copyright under a CC BY-NC-SA 04

*Associate Professor, Faculty of Mechanical and Electrical Engineering, Damascus University, Damascus, Syria. talal64.hammoud@damascusuniversity.edu.sy
** PHD Student - Faculty of Mechanical and Electrical Engineering, Damascus University, Damascus, Syria. abeerm.saleh@damascusuniversity.edu.sy

تعزيز نظام التعرف على المشي باستخدام حساسات الهواتف الذكية (IMU) وتقنيات التعلم العميق

د. طلال حمود*

عبير محسن صالح**

(تاريخ الإيداع 3 / 8 / 2024. قُبِل للنشر في 18/ 9 / 2024)

□ ملخّص □

في هذه المقالة، تم تطوير منهج لتحديد هوية الشخص بناءً على البيانات المجدولة التي تم الحصول عليها من أجهزة استشعار الهواتف الذكية، وخاصة حساسات السرعة الزاوية وحساسات التسارع الخطي. يستخدم المنهج بشكل أساسي قياسات الاستشعار كميزات للمشي لتحديد هوية الشخص. يتم تنظيم البيانات في جداول ولكن يتم تحويلها إلى صور بأبعاد محددة (n*m) حيث m هو عدد الميزات (6: 3 مكونات حساسات السرعة الزاوية و 3 مكونات حساسات التسارع الخطية) و n هو طول العينة؛ وهو يشير إلى فترة حركة المشي. تم الحصول على مجموعة البيانات من قاعدة بيانات OU-ISIR البيومترية. تم اختيار المعلمة n بعد العديد من المحاولات وكانت القيمة الأفضل 128. تم تحويل البيانات المنظمة إلى صور بأبعاد (128*6) ثم إدخالها إلى نموذج التعلم العميق المطور الذي يستخدم بشكل أساسي طبقات التعلم العميق (الالتفاف، التقييس التجمعي، وحدات الذاكرة، التمويه، التخفيف، الاستبدال والتجميع). تم اختيار قيم بعض البامترات من خلال عملية بحث للحصول على أفضل القيم مثل عدد الوحدات في LSTM (الذاكرة القصيرة والطويلة الأجل-Long Short Temporary Memory)، وخطوات طبقات التباين في النموذج ومعدل التعلم لعملية التعلم. بالإضافة إلى ذلك، تم استخدام المعالجة المتوازية في النموذج لتعزيز ميزات البيانات حيث أن عدد الميزات صغير، أظهر النموذج النهائي دقة عالية في تحديد الهوية (98.23%).

الكلمات المفتاحية: تحديد هوية الأفراد، ميزات المشي، مجموعة بيانات أجهزة الاستشعار الخاملة، نموذج التعلم العميق، ضبط المعاملات، المعالجة المتوازية

حقوق النشر : مجلة جامعة تشرين- سورية، يحتفظ المؤلفون بحقوق النشر بموجب الترخيص CC BY-NC-SA 04

* أستاذ مساعد – كلية الهندسة الكهربائية والميكانيكية، جامعة دمشق، دمشق، سورية.
talal64.hammoud@damascusuniversity.edu.sy

** طالبة دراسات عليا (دكتوراه) كلية الهندسة الكهربائية والميكانيكية، جامعة دمشق، دمشق، سورية.
ايميل: abeerm.saleh@damascusuniversity.edu.sy

مقدمة:

في الآونة الأخيرة، أصبحت أجهزة الاستشعار ذاتية القصور (Inertial sensors) مثل الجيروسكوبات ومقاييس التسارع معروفة على نطاق واسع لتطبيقاتها في اكتشاف الأنشطة البشرية. تمتلك هذه الأجهزة القدرة على تسجيل ديناميكيات الحركة لأجزاء مختلفة من الجسم وإرسال البيانات المجمعة إلى وحدة معالجة لاستخدامها في تطبيقات متعددة. يمكننا تصنيف الحركة البشرية كواحدة من عدة أنشطة من خلال تحليل البيانات المتدفقة (سواء في الزمن الحقيقي أو غير الحقيقي). وقد أثبتت هذه التقنية فائدتها في العديد من التطبيقات، وخاصة في مجالات الرياضة والطب. ومع ذلك، لم يكن هناك تركيز كبير على استخدام أجهزة الاستشعار القصورية في تحديد هوية الشخص بناءً على طريقة مشيه. يهدف تحديد هوية الشخص بناءً على المشي باستخدام أجهزة الاستشعار ذاتية القصور إلى التعرف على الشخص من بين مجموعة بيانات محددة مسبقاً من الأشخاص أثناء المشي، وذلك باستخدام حساس أو اكثر من الحساسات المثبتة على الجسم. يختلف هذا الموضوع عن موضوع مصادقة أو التحقق من هوية الشخص، حيث يتعامل الأخير مع مسألة تحديد ما إذا كان الشخص المحدد (باسم معين أو هوية معينة) – سواء كان يرتدي أجهزة الاستشعار (المضمنة) أو لا – هو الشخص المطلوب التحقق منه. باستناد إلى قراءات أجهزة الاستشعار ذاتية القصور لأنماط مشي الشخص، ينبغي أن يكون بالإمكان تحديد هوية ذلك الشخص بدقة ووضوح، نظراً لأن لكل فرد نمط مشي فريد يميزه عن الآخرين (Slemenšek et al [1]).

لقد تم تطبيق التعلم العميق وخوارزميات التعلم الآلي الأخرى بشكل واسع في تحديد الأنشطة البشرية، ومن المتوقع أن تؤدي هذه التقنيات أداءً جيداً أيضاً في تحديد هوية الأشخاص. على الرغم من الاستخدام الواسع لأساليب التعلم العميق، إلا أن بعض خوارزميات التعلم الآلي التقليدية لا تزال تقدم أداءً مكافئاً، خاصة في اكتشاف الأنشطة، مع متطلبات معالجة أقل بكثير عند التعامل مع كميات محدودة من البيانات. تصبح مسألة تحديد هوية الشخص ذات أهمية عندما يتم مشاركة جهاز قابل للارتداء من قبل مجموعة من الأفراد، ويكون من الضروري التعرف على الشخص الذي يرتدي أو يستخدم الجهاز. هذا الأمر قد يكون ذا فائدة كبيرة في الفرق الرياضية، حيث يتشارك اللاعبون أجهزة تتبع الأنشطة، ويصبح من الضروري تحديد من يرتدي الجهاز في أي وقت من الأوقات بشكل تلقائي لربط البيانات بملفه الشخصي. ولهذا السبب، أصبح من الضروري الآن معرفة من هو الشخص الذي يستخدم الجهاز حالياً (Taha et al in [2]).

1. الدراسات المرجعية

قام Shi et al في [3] بتحليل شامل للدراسات الحديثة في هذا المجال، وكشفوا عن اعتماد واسع على شبكات الالتفاف العصبية (Convolution Neural Networks: CNNs) أو نماذج الذاكرة القصيرة والطويلة الأمد (LSTM)لاستخراج ميزات المشي. ومع ذلك، لاحظوا قيداً كبيراً في هذه الأساليب: فعلى الرغم من أن شبكات CNNsتتفوق في التقاط جميع الخصائص، إلا أنها تواجه صعوبة في الحفاظ على المعلومات الزمنية التي تعد ضرورية لتحليل المشي. وعلى النقيض من ذلك، تواجه نماذج LSTM، التي تتميز بقدرتها على التعامل مع البيانات الزمنية، تحديات أداء مع التسلسلات الطويلة. لمعالجة هذه القيود، اقترح المؤلفون نهجاً جديداً يسمى SConvLSTM، يدمج بين شبكات CNNs ذات البعد الواحد (1D–CNN) وشبكات LSTM ثنائية الاتجاه. يهدف هذا النموذج الهجين إلى استخراج الميزات من بيانات الاستشعار الخام دون تدخل يدوي. في البداية، يتم استخدام 1D–CNN لالتقاط الميزات عالية الأبعاد من إشارات أجهزة الاستشعار القصورية، مع الحفاظ على الجوانب الزمنية وضغط متجهات

الميزات. بعد ذلك، يتم استخدام شبكة LSTM ثنائية الاتجاه لاستخراج الميزات الزمنية بشكل إضافي. ومن الجدير بالذكر أن الطريقة المقترحة تعمل على إطارات بيانات بطول ثابت، مما يلغي الحاجة إلى اكتشاف دورة المشي ويقلل من احتمال حدوث أخطاء في الدقة نتيجة أخطاء اكتشاف الدورة. تم تقييم فعالية SConvLSTM على ثلاث مجموعات بيانات معيارية مستخدمة على نطاق واسع UCI-HAR، HuGaDB وWISDM. أظهرت النتائج أداءً متفوقاً مقارنة بالأساليب المتطورة الأخرى عبر جميع مجموعات البيانات الثلاث، مما يبرز فعالية النهج المقترح في مهام التعرف على المشي.

في [4] درس المؤلفون الإمكانية الواعدة لتحليل المشي باستخدام أجهزة الاستشعار القصورية للتعرف على المستخدم، معتبرين أنها توجه بحثي واعد في الأبحاث الحديثة. رغم التقدم في تقنيات التعلم العميق، لا يزال تحدي نقص بيانات التدريب يعيق تطوير نماذج المشي المتينة. للتغلب على هذه العقبة، اقترح المؤلفون نهجاً جديداً لتوسيع بيانات المشي القائمة على أجهزة الاستشعار القصورية. تم تقديم خوارزميتين لتحويل البيانات مع الحفاظ على العلامات، وهما ATD: Arbitrary Time Deformation و SMP: Stochastic Magnitude Perturbation. لتوليد بيانات تدريب إضافية من بيانات المشي الحقيقية. يقوم ATD بتعديل المعلومات الزمنية لبيانات المشي باستخدام قيم عشوائية، بينما يقوم SMP بتغيير القدر بشكل عشوائي، مما يؤدي إلى إدخال تنوع في البيانات المُضافة. بعد ذلك، تم تطوير نموذج عام للتعرف على المشي باستخدام شبكات الالتفاف العصبية (CNNs). يقوم هذا النموذج بدمج خوارزميات ATD و SMP بفعالية لإنتاج بيانات مُضافة تحاكي التنوعات الطبيعية الموجودة في البيانات الحقيقية. تم تقييم النهج المقترح بدقة باستخدام مجموعتي بيانات متاحتين علناً، إحداهما تم جمعها في ظروف غير مقيدة والأخرى تحتوي على أكبر عدد من المشاركين. تشير نتائج التجارب إلى أن استخدام ATD أو SMP بشكل فردي أدى إلى تحسينات كبيرة في أداء التعرف عبر كميات مختلفة من بيانات التدريب. بالإضافة إلى ذلك، أدى الجمع بين ATD و SMP إلى تحقيق دقة أعلى. مع دمج ATD وSMP، حقق النموذج أداءً منافساً مقارنة بالأبحاث المتقدمة على كلا مجموعتي البيانات.

في [5] قام المؤلفون بإجراء تحقيق في تحديد هوية الشخص عبر عدة كاميرات، مُدركين أهميته في تطبيقات الرؤية الحاسوبية، وخاصة لتتبع الأفراد عبر مشاهد متنوعة. يعتبر التعرف على المشي، الذي يعتمد بشكل أساسي على نمط المشي، تقنية بارزة لهذا الغرض بسبب الخصائص الفريدة للمشي البشري التي تسهل التعرف على الشخص من مسافة. ومع ذلك، قد تتأثر فعالية التعرف على المشي بعوامل مثل أوضاع التقاط الصور أو الفيديو. استجابةً لهذا التحدي، اقترح المؤلفون نهجاً جديداً للتعرف على المشي من أجل تحديد هوية الشخص. يبدأ النهج بتقدير زوايا المشي، يليه عملية التعرف باستخدام شبكات الالتفاف العصبية (CNNs). يتم استخدام نماذج CNN متعددة المهام جنباً إلى جنب مع صور طاقة المشي المستخرجة (Gait Energy Images: GEIs) لتقدير الزوايا والتعرف. يتم اشتقاق GEIs من خلال اكتشاف الأجسام المتحركة باستخدام تقنيات طرح الخلفية. تم تقييم الطريقة المقترحة بدقة عبر ثلاث مجموعات بيانات معترف بها (B)-CASIA، OU-ISIR، وOU-MVLP، مع تقييم إضافي لنمذجة الخلفية باستخدام مجموعة بيانات نمذجة الخلفية الأولية (SBI). تُظهر التقييمات فعالية طريقة التعرف على المشي المقترحة، حيث حققت دقة تتجاوز 98% في جميع مجموعات البيانات تقريباً. ومن الجدير بالذكر أن النتائج تفوقت على تلك التي حصلت عليها الأساليب الحالية لمجموعات بيانات (B)-CASIA وOU-MVLP، وحققت أفضل أداء لمجموعة بيانات OU-ISIR.

في عملنا، كانت المفاتيح الرئيسية للنموذج المطور هي:

- استخدام تحويل البيانات من بيانات منظمة مجدولة رقمية ضمن جدول إلى مصفوفة مع عينات زمنية.
- استخدام عملية ضبط لاختيار أفضل قيم لبعض الباميترات.
- استخدام المعالجة المتوازية بين الطبقات في نموذج التعلم العميق.

وصف مجموعة البيانات: تتألف مجموعة البيانات من بيانات أجهزة الاستشعار ذاتية القصورية من قاعدة بيانات OU-ISIR. الهدف الرئيسي لقاعدة بيانات OU-ISIR الخاصة بالمشي هو دعم الجهود البحثية التي تركز على إنشاء وفحص وتقييم الخوارزميات الخاصة بتحديد هوية الإنسان بناءً على المشي. يتم توزيع قاعدة بيانات OU-ISIR للمشي من قبل معهد البحث العلمي والصناعي (ISIR) بجامعة أوساكا (OU)، التي تمتلك حقوق الطبع والنشر لمجموعة البيانات. تم جمع هذه المجموعة من البيانات من الحضور خلال برنامج توعية استمر لمدة خمسة أيام أقيم في طوكيو، اليابان في عام 2011. تم طلب من كل ضيف توقيع نموذج موافقة يجيز استخدام معلوماته للدراسة. بالإضافة إلى ذلك، قدم كل منهم معلومات بيولوجية أساسية مثل العمر والجنس. قدموا أكبر قاعدة بيانات في العالم لمعلومات المشي القائمة على أجهزة الاستشعار ذاتية القصور [6]. تحتوي على بيانات لـ741 شخصاً متحركاً. تم استخدام أربعة أجهزة استشعار مثبتة على الحزام كما هو موضح في الشكل التالي

الشكل 1: حزام مع أربعة حساسات

البيانات التي تم جمعها لم تكن كلها بنفس المستوى جميعها من حيث إمكانية استخدامها للتمييز بين الأفراد بعد القيام بعملية معالجة أولية أساسية لاستخراج البيانات المفيدة والتخلص من البيانات غير الصالحة. نتيجة لذلك، تم العامل مع البيانات على قسمين، القسم الاول وهو الأكثر جدوى ويحوي على بيانات مفيدة وواضحة وتم إنشاء المجموعة الأولية للبيانات بأكبر عدد ممكن من الأفراد. وفي الوقت نفسه، تم التعامل بطريقة أخرى مع إعطاء أهمية لتحسين هذه المجموعة مع تعديل نوع الحساس وموقعه الدقيق، وظروف الأرض، والموقع. سجل مستشعر IMUZ (Inertial Measurement Unit on axis z) المركزي بيانات المشي على سطح مستوٍ لـ744 شخصاً (389 رجلاً و355 امرأة) تتراوح أعمارهم بين 2 إلى 78 عاماً. باستخدام قيود مسار الحركة والارتباط الذاتي للإشارات، تم استخراج تسلسلين مميزين للمشي على سطح مستوٍ لكل فرد بشكل تلقائي ضمن هذه المجموعة الفرعية [1].

[1] **(more details: OU-ISIR Biometric Database (osaka-u.ac.jp)).**

ركزت المجموعة الفرعية الثانية بشكل أساسي على اختلافات موضع المستشعر وانحدار الأرض. استعدنا طريقتين للمشي على سطح مستوٍ وعلى منحدر صاعد، وسلسلة أخرى للمشي على منحدر هابط لكل فرد ولكل مستشعر. تضمنت هذه المجموعة الفرعية 495 شخصاً تم جمع بياناتهم باستخدام ثلاثة مستشعرات IMUZ، و408 أشخاص تم جمع بياناتهم باستخدام الهاتف الذكي. في هذه المجموعة الفرعية، تم استخراج البيانات يدوياً عن طريق المزامنة مع مقطع فيديو تم تسجيله في الوقت نفسه. تم استخراج البيانات تلقائياً، ولكل هوية فردية هناك ملفان. تحتوي الصفوف الأولى من كل ملف على عدد الصفوف الموجودة في الملف؛ وهذا يشير إلى عدد العينات التي تم تسجيلها. على سبيل المثال، إذا كان هذا الرقم هو 600، فإن ذلك يعني أن الفرد قد مشى لفترة زمنية تعادل 600 عينة من القياسات. سميت البيانات الرئيسية باسم OU-ISIR.

2. النموذج المطور

تحويل مجموعة البيانات:

بعد شرح تنسيق مجموعة البيانات، لنفترض أن عدد العينات للشخص "X" في ملفه الأول هو"n" ، بالتالي يحتوي الملف على بيانات بحجم $6 * n$ سيتم إعادة تشكيل هذه البيانات لتصبح $6 * n_1 * n_2$، حيث يمثل "n_2" الوقت الكافي لالتقاط بصمة المشي للشخص، وبالتالي يكون "n_1" هو عدد بصمات المشي لهذا الشخص، وكل بصمة مشي تحتوي على n_2 من بيانات العينات.

هيكل النموذج:

يبدأ هيكل النموذج بطبقة إدخال تليها طبقة Masking للتعامل مع تسلسلات الإدخال المتغيرة الطول. يتم استخدام طبقة LSTM لالتقاط التسلسل الزمني للبيانات، تليها طبقة Dropout للتقليل من فرط التكيّف. بالإضافة إلى ذلك، يتم استخدام سلسلة من الطبقات الالتفافية (Convolutional Layers) مع طبقات التقييس الدفعية (Batch Normalization) و activation function لالتقاط الأنماط المحلية local patterns في البيانات. كما يتضمن النموذج مكونات مخصصة مثل كتلة Squeeze-Excite لتعزيز إعادة تقويم الميزات. يتم تحديد معلمات النموذج الفائقة (Hyperparameters)، بما في ذلك عدد وحدات LSTM، ومعدل الإسقاط dropout rate، وأحجام المرشحات، وخطوات الطبقات strides، ومعدل التعلم learning rate، ضمن تعريف النموذج. يتم استخدام Keras Tuner لضبط البامترات الفائقة (hyper-parameters) باستخدام تقنية Random Search، مع تنفيذ متوازي لتسريع العملية. تُستخدم طريقة tuner.search لبدء عملية ضبط البامترات الفائقة، بما في ذلك إيقاف التدريب المبكر لمنع فرط التدريب overfitting أثناء التدريب.

النقاط القوية في هذا الهيكل هي:

- **بنية الشبكة العصبية** :يجمع النموذج بين طبقة LSTM تليها طبقات التفاف 1D-Convolutional وطبقات إضافية للتقييس والتنشيط. تُعرف هذه البنية باسم الشبكة العصبية المتعددة المقاييس Multi LSTM Fully Convolutional Network (MLSTM-FCN)، حيث تجمع بين قوة LSTM في التعامل مع البيانات التسلسلية وقدرة الطبقات الالتفافية على التقاط الأنماط المحلية.
- **ضبط البامترات الفائقة باستخدام Keras Tuner**: يتم استخدام Keras Tuner لضبط البامترات الفائقة، وخاصة باستخدام تقنية Random Search، التي تعد تقنية فعالة لأخذ عينات من البامترات الفائقة من مساحة

محددة. يتم تحسين معلمات مثل عدد وحداتLSTM ، ومعدل الإسقاط، وحجم المرشح، وخطوة المرشح، ومعدل التعلم لتحسين أداء النموذج.

- **التنفيذ المتوازي** :استخدام Random Search يقوم بشكل طبيعي عدة تجارب بالتوازي لاستكشاف مساحة البامترات الفائقة بشكل فعال. يتيح التنفيذ المتوازي البحث السريع عن البامترات الفائقة، وهو أمر مهم عند التعامل مع النماذج المعقدة أو مجموعات البيانات الكبيرة.
- **المكونات المخصصة** :لتعزيز القدرة التمثيلية للنموذج من خلال دمج آليات مثل إعادة تقويم الميزاتFeature Recalibration. تأخذ هذه المكونات Tensor كمدخل وتطبق عملية Squeeze–and–Excite، التي تساعد النموذج على التركيز على الميزات المهمة وتثبيط الميزات الأقل أهمية، عبر حساب متوسط التنشيط عبر القنوات باستخدام نمط التجميع Global Average Pooling. بعد ذلك، يتم إعادة تشكيل الـ Tensor الناتج ليكون له نفس شكل الـ Tensor المدخل. يحتوي النموذج على طبقتين Dense، تقلل الأولى عدد الميزات، وتقوم الطبقة الثانية بعملية Sigmoid لضبط الميزات بين 0 و1، لتعمل كأوزان اهتمام Attention Weights. وأخيراً، يتم تطبيق عملية ضرب عنصر بعنصر بين Tensor المدخل وأوزان الاهتمام المحسوبة، لإعادة تقويم الميزات بشكل فعال.
- **الإيقاف المبكر Early stopping**: يتم تنفيذ الإيقاف المبكر كاستدعاء أثناء تدريب النموذج. تساعد هذه التقنية على منع فرط التدريب من خلال مراقبة خطأ التعلم وإيقاف عملية التدريب عندما يتوقف الخطأ عن التناقص لعدد معين عينات التدريب.

باستخدام Keras Tuner، يصبح ضبط البامترات الفائقة عملية قابلة للتكرار، مما يسمح بتحقيق نتائج متسقة عبر تجارب مختلفة. يُطلق على النموذج النهائي اسم الشبكة العصبية المتعددة المقاييس المحسّنة Optimized Multi LSTM Fully Convolutional Network (OMLSTM–FCN). وبالتالي هذه النموذج من خلال البنية وضبط البارمترات والتنفيذ الموازي لبنية الشبكة التي تكون قريبة من U–Net يقدم إضافات علمية قيمة ضمن هذه المجال ويتميز عن غيره بهذه النقاط.

3. التنفيذ العملي والنتائج

تم تقسيم مجموعة البيانات إلى جزئين: جزء للتدريب وآخر للاختبار. تم التقسيم يدوياً لضمان احتواء كلا الجزئين على عينات من جميع هويات الأشخاص الموجودة في مجموعة البيانات. تم اختيار عدد العينات الذي يعتبر كافياً لحفظ بصمة المشي ليكون 128 عينة، وذلك بعد العديد من المحاولات.

T0 Gx, Gy, Gz, Ax, Ay, Az
T1 Gx, Gy, Gz, Ax, Ay, Az
T2 Gx, Gy, Gz, Ax, Ay, Az
T3 Gx, Gy, Gz, Ax, Ay, Az
.
.
.
TN Gx, Gy, Gz, Ax, Ay, Az

الشكل 2: البيانات قبل التحويل

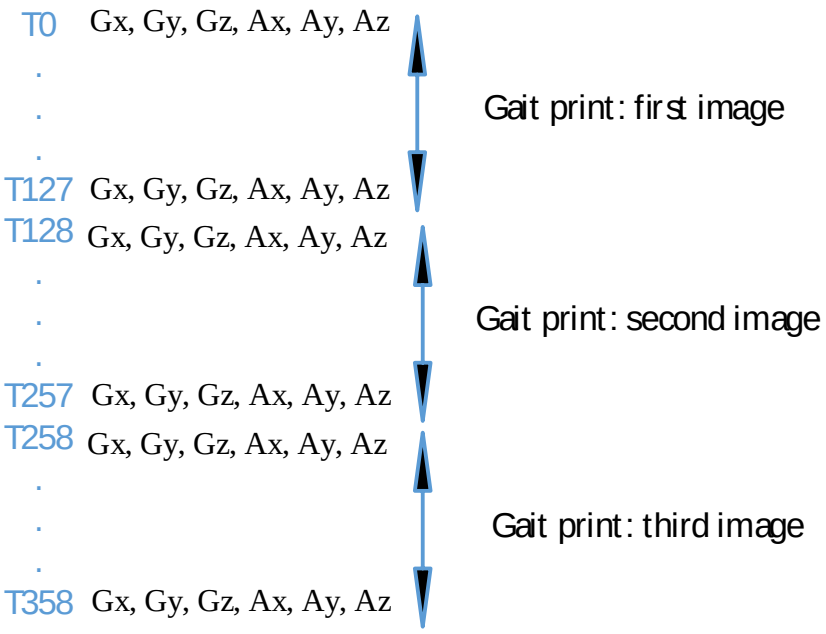

الشكل 3:البيانات بعد التحويل

الدقة والخطأ لعملية التدريب والاختبار في الأشكال التالية

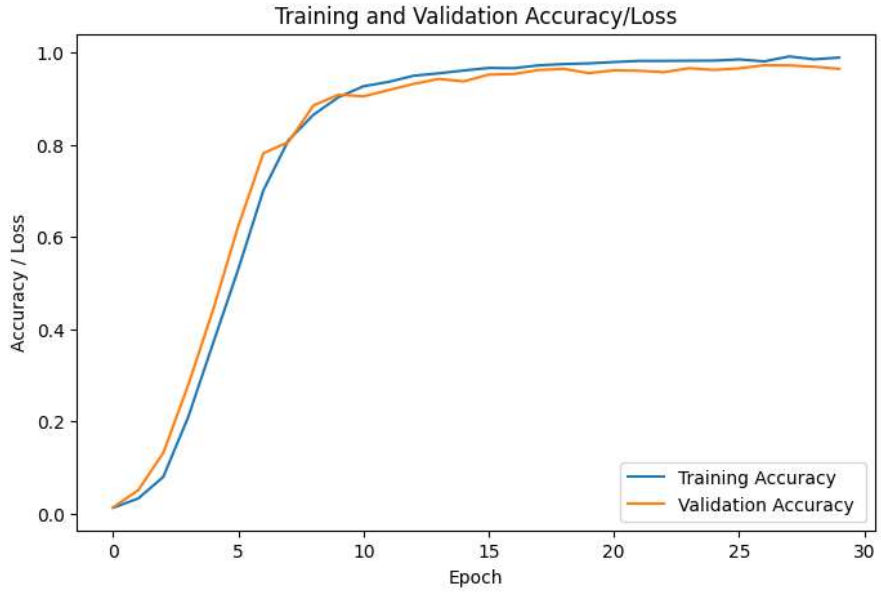

الشكل 4: دقة التدريب والتحقق

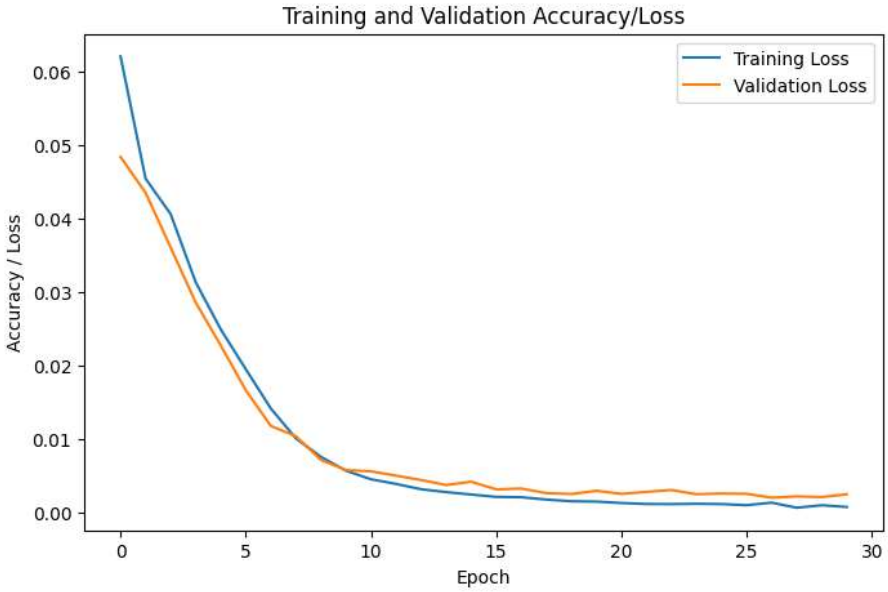

الشكل 5: خطأ التدريب والتحقق

تم ضبط البامترات التالية: عدد الوحدات في طبقة LSTM (الذاكرة القصيرة والطويلة الأجل)، وخطوات طبقات الالتفاف (Strides)في النموذج، ومعدل التعلم في عملية التعلم. يوضح الشكل 6 النموذج النهائي. يُظهر الشكل كيفية تنفيذ المعالجة المتوازية.

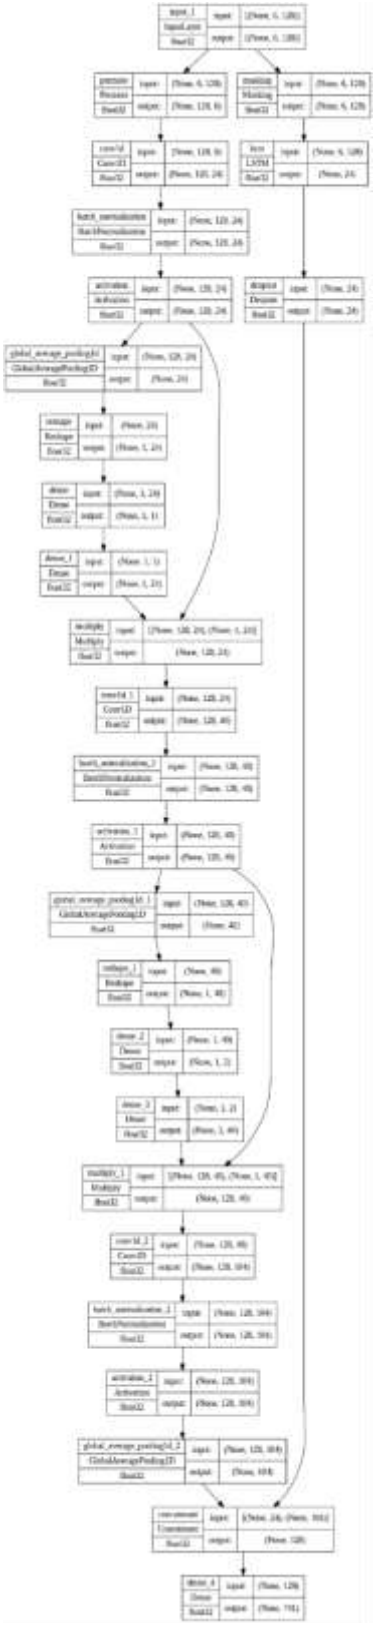

الشكل 6 : بنية النموذج النهائية

في حال أردنا التنفيذ العملي نحتاج إلى جمع قاعدة بيانات محلية حسب الاستخدام وتدريب المنهجية الخاصة بنا عليها ومن ثم استخدام النموذج المدرب بشكل offline مع إمكانية تحديث النموذج المدرب عند دخول صور جديدة.

النتائج والمناقشة:

العوامل المؤثرة على الدقة العالية (98.23%) التي حققها النموذج. يمكن عزو الدقة العالية التي حققها النموذج إلى عدة عوامل وخيارات منهجية رئيسية:

- تحويل البيانات المنظمة structured data إلى مصفوفة: من خلال تحويل البيانات المنظمة إلى مصفوفة، حيث يمثل كل مجموعة من 128 صفاً بصمة المشي، يستفيد النموذج بفعالية من المعلومات المكانية المتأصلة في البيانات على شكل مصفوفة. يسهم هذا التحويل في استخراج أنماط وميزات دقيقة موجودة في بصمات المشي التي ربما لم تكن واضحة بسهولة في التنسيق الجدولي الأصلي للبيانات قبل عملية التحويل. المصفوفة تلتقط العلاقات المكانية والأنماط، مما يمكّن النموذج من التمييز بشكل أفضل بين الأفراد المختلفين بناءً على مشيتهم.
- ضبط معلمات النموذج: ساعد استخدام عملية ضبط معلمات دقيقة على تحديد التكوين الأمثل للمعلمات لتعظيم الأداء. يتيح استخدام تقنيات مثل البحث العشوائي (Random Search) استكشاف مجموعة واسعة من تراكيب الباميترات، مما يضمن ضبط النموذج بشكل دقيق لخصائص البيانات. من المرجح أن هذه العملية ساهمت في قدرة النموذج على التعميم بشكل جيد على البيانات غير المرئية وتحقيق دقة عالية.
- المعالجة المتوازية بين الطبقات: يساهم تضمين المعالجة المتوازية بين الطبقات في نموذج التعلم العميق في تعزيز كفاءة الحوسبة وربما يساعد في تحسين استخراج الميزات. تتيح المعالجة المتوازية تنفيذ الحسابات بشكل متزامن عبر طبقات متعددة، مما يؤدي إلى تسريع عملية التدريب والاستدلال. هذا يمكن أن يكون مفيداً بشكل خاص في النماذج المعقدة مثلOMLSTM–FCN ، حيث تساعد المعالجة المتوازية في التعامل مع عبء الحوسبة بفعالية، مما يؤدي إلى تحسين الأداء.
- هيكلية النموذج: يجمع هيكل OMLSTM–FCN بين نقاط القوة لكل من طبقات LSTM وطبقات الالتفاف، حيث تستخدم LSTM لالتقاط التبعيات الزمنية في تسلسلات المشي وطبقات الالتفاف لاستخراج الميزات المكانية من المصفوفة التي تحوي بصمة المشي. هذه الهيكلية الهجينة مع عملية التحسين تُمكِّن النموذج من التقاط الأنماط المحلية والعالمية الموجودة في البيانات بفعالية، مما يساهم في قوة التمييز والدقة العالية التي يحققها.

المنهج المطور حقق دقة وصلت إلى 98.23% بينما حقق المؤلفون في [4] دقة تصل إلى 89.99% وبالعمل على نفس قاعدة البيانات OU–ISIR. والمؤلفون في [5] حققوا 98.7% دقة على نفس البيانات ولكن تم اختيار أفضل زاوية لجهة الكاميرا. نلاحظ أن الطريقة المطورة تحقق نتائج ممتازة وأفضل من غيرها.

الاستنتاجات والتوصيات:

في الختام، تقدم هذه الدراسة منهجاً مبتكراً لتحديد الهوية باستخدام بيانات المشي التي تم الحصول عليها من حساسات الهواتف الذكية، وتحديداً الجيروسكوبات ومقاييس التسارع. تُستخدم القياسات المستشعرة المنظمة كميزات للمشي لتحديد الأفراد. تم تنظيم البيانات في البداية في جداول، ثم تم تحويلها إلى مصفوفة بأبعاد (128*6)، حيث يمثل كل صف فترة من حركة المشي وكل عمود يمثل مكوناً من مكونات الحساس (3 جيروسكوبات و3 مقاييس تسارع). تم استخدام مجموعة البيانات من قاعدة بيانات OU–ISIR البيومترية. من خلال عملية ضبط معلمات واسعة النطاق، تم تحديد القيمة المثلى للمعامل 'n' (طول العينة) لتكون 128. بعد ذلك، يتم إدخال هذه التمثيلات بشكل مصفوفات للبيانات

المنظمة في نموذج التعلم العميق الذي يتألف من طبقات التفاف، ووحدات ذاكرة (LSTM)، وتطبيع الدفعات، وتغطية، وإسقاط، وتبديل، وتجميع. تركز عملية الضبط على معلمات مثل عدد الوحدات في LSTM، وخطوات طبقات الالتفاف، ومعدل التعلم. علاوة على ذلك، تعزز المعالجة المتوازية داخل النموذج من استخراج الميزات نظراً للعدد المحدود من الميزات. نتيجة لذلك، يحقق النموذج المطور دقة استثنائية في تحديد الهوية بنسبة 98.23%، مما يؤكد فعالية المنهجية المقترحة في تحديد الأفراد بدقة استناداً إلى أنماط مشيهم الملتقطة من خلال بيانات حساسات القصور الذاتي.

References:

1. Slemenšek, J., Fister, I., Geršak, J., Bratina, B., van Midden, V. M., Pirtošek, Z., & Šafarič, R. (2023). Human gait activity recognition machine learning methods. Sensors, 23(2), 745.
2. Taha, K., Yoo, P. D., Al-Hammadi, Y., Muhaidat, S., & Yeun, C. Y. (2024). Learning a deep-feature clustering model for gait-based individual identification. Computers & Security, 136, 103559.
3. Shi, L. F., Liu, Z. Y., Zhou, K. J., Shi, Y., & Jing, X. (2023). Novel deep learning network for gait recognition using multimodal inertial sensors. *Sensors*, *23*(2), 849.
4. Tran, L., & Choi, D. (2020). Data augmentation for inertial sensor-based gait deep neural network. *IEEE Access*, *8*, 12364-12378.
5. Elharrouss, O., Almaadeed, N., Al-Maadeed, S., & Bouridane, A. (2021). Gait recognition for person re-identification. The Journal of Supercomputing, 77, 3653-3672.
6. Iwama, H., Okumura, M., Makihara, Y., & Yagi, Y. (2012). The OU-ISIR gait database comprising the large population dataset and performance evaluation of gait recognition. *IEEE Transactions on Information Forensics and Security*, *7*(5), 1511-1521.
7. Ye, M., Shen, J., Lin, G., Xiang, T., Shao, L., & Hoi, S. C. (2021). Deep learning for person re-identification: A survey and outlook. *IEEE transactions on pattern analysis and machine intelligence*, *44*(6), 2872-2893.
8. Gorgolis, N., Hatzilygeroudis, I., Istenes, Z., & Gyenne, L. G. (2019, July). Hyperparameter optimization of LSTM network models through genetic algorithm. In *2019 10th International Conference on Information, Intelligence, Systems and Applications (IISA)* (pp. 1-4). IEEE.
9. Noreen, N., Palaniappan, S., Qayyum, A., Ahmad, I., Imran, M., & Shoaib, M. (2020). A deep learning model based on concatenation approach for the diagnosis of brain tumor. *IEEE Access*, *8*, 55135-55144.
10. Hu, J., Shen, L., & Sun, G. (2018). Squeeze-and-excitation networks. In *Proceedings of the IEEE conference on computer vision and pattern recognition* (pp. 7132-7141).