SEBHA UNIVERSITY CONFERENCE PROCEEDINGS, VOL.5 NO. 4 2026
DOI: 10.51984/05YYTF47

وقائع مؤتمرات جامعة سبها
Sebha University Conference Proceedings
Conference Proceeding homepage: http://www.sebhau.edu.ly/journal/CAS

تصنيف الحركات البشرية باستخدام شبكة LSTM اعتمادا على بيانات هيكلية مجمعة بواسطة ألة تصوير Kinect في بيئة و اقعية

يايا أحمد[*a] عمر شيبة[b] حمودة شفتر[c]

[*a]جامعة سبها، كلية العلوم، قسم علوم الحاسب، سبها، ليبيا
[b] جامعة سبها، كلية تقنية المعلومات، قسم علم البيانات والذكاء الاصطناعي، سبها، ليبيا
[c] جامعة سبها، كلية تقنية المعلومات، قسم علوم الحاسب، سبها، ليبيا

الملخص

أصبح تحليل الحركات البشرية من المجالات البحثية المهمة في تطبيقات إعادة التأهيل الحركي و الأنظمة الذكية. تهدف هذه الدراسة إلى بناء نموذج يعتمد على الشبكات العصبية العميقة لتصنيف الحركات البشرية إلى حركات صحيحة وأخرى خاطئة باستخدام بيانات هيكلية تم جمعها في بيئة واقعية بواسطة كاميرا Kinect . شملت المنهجية المستخدمة عدة مراحل تضمنت جمع البيانات، واستخراج النقاط الهيكلية (Key points) ، والمعالجة المسبقة، وتحويل البيانات إلى تمثيل نسبي لتقليل تأثير اختلاف مواضع الأشخاص أثناء التصوير، إضافة إلى ذلك استخراج الخصائص الزمنية للحركة. بعد ذلك تم بناء نموذج يعتمد على نموذج الذاكرة طويلة–قصيرة المدى (LSTM) لمعالجة التسلسلات الزمنية للحركة البشرية. أظهرت النتائج أن النموذج المقترح حقق أداء جيد في تصنيف الحركات، حيث بلغت دقة التصنيف (91.20%) مع قيم مرتفعة لمقاييس Precision و Recall و F1-score، مما يشير إلى قدرة النموذج على التعميم والتعامل مع البيانات الواقعية المحدودة. كما أظهرت الدراسة من خلال المقارنة مع نموذج ConvLSTM أن النماذج الأبسط زمنيا قد تكون أكثر ملاءمة للبيانات الواقعية الصغيرة مقارنة بالنماذج المكانية–الزمنية الأكثر تعقيدا، وهو ما يؤكد أهمية اختيار النموذج بناء على طبيعة البيانات وليس على تعقيد المعمارية فقط.

الكلمات المفتاحية:

التعلم العميق
التأهيل الحركي
تصنيف الحركة
تحليل الحركة البشرية

Human Motion Classification Using LSTM Based on Real-World Kinect Skeletal Data

Yaya Amo Ahmed, Omar A. Shiba, Hamouda Chantar

[*a]University of Sebha, Faculty of Science, Department of Computer Science, Sebha, Libya
[b]University of Sebha, Faculty of Information Technology, Department of Data Science & Artificial Intelegente, Sebha, Libya
[c]University of Sebha, Faculty of Information Technology, Department of Computer Science, Sebha, Libya

Keywords:

Human Motion Analysis
Deep Learning
LSTM
Kinect
Motion Classification

ABSTRACT

Human motion analysis has become an important research area in physical rehabilitation applications and intelligent systems. This study aims to develop a deep neural network–based model for classifying human movements into correct and incorrect actions using skeletal data collected in a real-world environment through a Microsoft Kinect sensor. The adopted methodology involved several stages, including data collection, extraction of skeletal key points, preprocessing, and transforming the data into a relative representation to reduce the effect of differences in subjects' positions during recording. In addition, temporal motion features were extracted. Subsequently, a model based on a Long Short-Term Memory (LSTM) network was developed to process human motion time-series sequences. The results demonstrated that the proposed model achieved good performance in motion classification, reaching an accuracy of 91.20%, along with high Precision, Recall, and F1-score values. This indicates the model's ability to generalize and effectively handle limited real-world data. Furthermore, the study showed through comparison with the ConvLSTM model that temporally simpler models may be more suitable for small real-world datasets than more complex spatial–

*Corresponding author:
E-mail addresses: yaya.ahmad@sebhau.edu.ly, (O. A. Shiba) oma.shiba@sebhau.edu.ly, (H. Chantar) ham.chantar@sebhau.edu.ly
Article History : Received 30 May 2026 - Received in revised form 30 September 2026 - Accepted 11 November 2026

temporal architectures. This finding emphasizes the importance of selecting the appropriate model based on the nature of the data rather than relying solely on architectural complexity

1. المقدمة

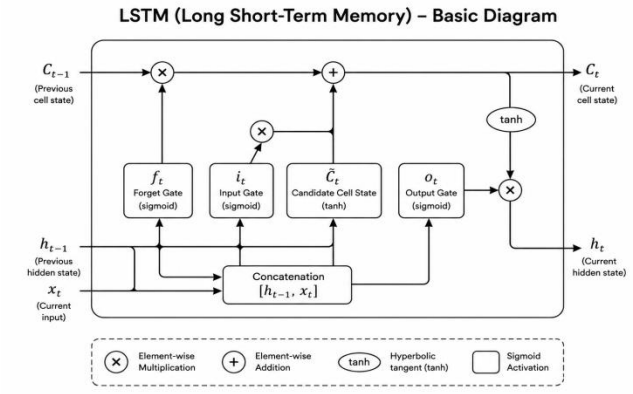
سجلت السنوات الأخيرة تطورا ملحوظ في تقنيات تحليل الحركة البشرية باستخدام تقنيات الذكاء الاصطناعي والتعلم العميق، نظرا لأهميتها في مجالات إعادة التأهيل الحركي، و الطب الرياضي، و الأنظمة الذكية [1].
على سبيل المثال، التصنيف الخاطئ لحركات المرضى المجال الطبي يترتب عليه تجاهل حالات طبية تحتاج الى علاج. تعد الكاميرات الحسية مثل Kinect من الحلول منخفضة التكلفة القادرة على توفير بيانات هيكلية للحركة البشرية بصورة لحظية وبدقة مناسبة لتطبيقات تحليل الحركة [2].
تعتمد أغلب الدراسات السابقة على مجموعات بيانات جاهزة و كبيرة الحجم يتم جمعها داخل بيئات مخبرية منظمة، الأمر الذي قد لا يعكس التحديات الحقيقية للبيئات الواقعية مثل الضوضاء، وتغير الإضاءة، واختلاف زوايا التصوير، وقلة عدد العينات. لذلك ظهرت الحاجة إلى دراسة مدى كفاءة نماذج التعلم العميق عند التعامل مع بيانات مجمعة من واقعية بعدد محدود نسبيا من المشاركين فى تسجيل العينات و كذلك عدد محدودة من العينات المجمعة .
تهدف هذه الدراسة إلى بناء نموذج يعتمد على شبكة الذاكرة طويلة قصيرة المدى Long Short Term Memory (LSTM) لتصنيف الحركات البشرية الصحيحة والخاطئة اعتمادا على بيانات هيكلية تم جمعها بواسطة كاميرا Kinectضمن ظروف واقعية. كما تهدف الدراسة إلى تقييم مدى ملاءمة نموذج LSTM مقارنة بنموذج ConvLSTM عند التعامل مع البيانات الصغيرة ومحدودة العينات، بهدف تحديد النموذج الأكثر كفاءة في البيئات الواقعية ذات الموارد المحدودة.

1. الدراسات السابقة

شهد مجال تحليل الحركات البشرية تطورا ملحوظ خلال السنوات الأخيرة، خاصة مع تطور تقنيات التعلم العميق وظهور البيانات الهيكلية المستخرجة من أنظمة التقاط الحركة مثل Kinect و Vicon وقد ركزت العديد من الدراسات على استخدام نماذج التعلم العميق لتحليل الحركات البشرية والتعرف على الأنشطة الحركية وتقييم الأداء الحركي في التطبيقات العلاجية والرياضية. وفيما يلي عرض لأبرز الدراسات المرتبطة بموضوع البحث الحالي.
تناولت الدراسة [3] إمكانية تصنيف الحركات البشرية باستخدام بيانات الهيكل العظمي المستخرجة من مستشعر Kinect، حيث اعتمدت على تتبع المفاصل البشرية وتحويلها إلى بيانات ثلاثية الأبعاد لاستخدامها في عملية التصنيف. وأظهرت النتائج فعالية بيانات Skeleton في تمثيل الحركة البشرية وتحقيق دقة جيدة في التعرف على الأنشطة الحركية، إلا أن الدراسة ركزت بصورة أساسية على التصنيف التقليدي للحركات دون التركيز على تحليل التسلسل الزمني العميق للحركة.
وقدمت الدراسة [4] نموذج قائم على Bidirectional LSTM لتحليل التسلسل الزمني للحركات البشرية اعتمادا على بيانات الهيكل العظمي باستخدام بنية Seq2Seq ، حيث أظهرت النتائج تحسن ملحوظ في دقة التعرف على الأنشطة البشرية مقارنة بالطرق التقليدية. وتدعم هذه الدراسة أهمية استخدام شبكات LSTM في معالجة البيانات الحركية المتسلسلة.
ركزت الدراسة [5] على تقييم حركات إعادة التأهيل الحركي باستخدام تقنيات التعلم العميق وبيانات الهيكل العظمي، حيث بينت النتائج قدرة النماذج العميقة على التمييز بين الحركات الصحيحة و الخاطئة بدقة عالية في التطبيقات العلاجية. كما تناولت الدراسة [6] دمج الخصائص المكانية و الزمنية للحركة البشرية باستخدام نموذج Spatio-Temporal LSTM لتحسين التعرف على الأنشطة الحركية المعقدة، وأظهرت النتائج أن دمج العلاقات الزمنية والمكانية ساهم بصورة واضحة في تحسين أداء النموذج. في حين اقترحت الدراسة [7] نموذج هجين يجمع بين Transformer و LSTM مع آلية Attention لتحسين التعرف على الحركات البشرية، حيث حقق النموذج دقة مرتفعة في استخراج الخصائص الحركية المعقدة، إلا أنه تميز بارتفاع التعقيد الحسابي والحاجة إلى موارد تدريب كبيرة. بالإضافة للدراسات المذكورة، استخدمت العديد من الدراسات مثل [8]، [9]، [10]، [11] نماذج التعلم الآلي Machine learning و نماذج التعلم العميق Deep learning في تصنيف و تمييز الحركات والنشاط البشرى. على الرغم من التطور الكبير في الدراسات السابقة المتعلقة بالتعرف على الحركات البشرية باستخدام بيانات الهيكل العظمي، فإن معظم الدراسات اعتمدت على مجموعات بيانات قياسية أو نماذج معقدة تتطلب موارد حسابية مرتفعة. إضافة إلى ذلك، لا تزال الدراسات التي تعتمد على بيانات واقعية تم جمعها ميدانيا لتقييم الحركات الصحيحة والخاطئة محدودة نسبيا. لذلك، يهدف البحث الحالي إلى تطوير نموذج قائم على شبكة LSTM لتحليل وتصنيف الحركات البشرية باستخدام بيانات هيكلية تم جمعها في بيئة واقعية، بما يحقق توازن بين الدقة وبساطة النموذج. كما تسعى الدراسة الحالية إلى تقييم مدى كفاءة نماذج التعلم العميق عند التعامل مع بيانات محدودة الحجم تم جمعها في ظروف واقعية، وهو جانب لم يحظَ باهتمام كاف في الدراسات السابقة.

2. نموذج LSTM

تصنف شبكات الذاكرة طويلة قصيرة المدى Long Short-Term Memory (LSTM - كأحد أنواع الشبكات العصبية المتكررة Recurrent Neural Networks - RNN) المصممة بشكل خاص لمعالجة البيانات المتسلسلة و تحليل العلاقات الزمنية طويلة المدى [12].



الشكل1: بنية نموذج LSTM

تم تطوير هذا النموذج لمعالجة مشكلة تلاشي التدرج Vanishing Gradient Problem)التي تواجه الشبكات العصبية التقليدية عند التعامل مع التسلسلات الزمنية الطويلة.
يعتمد نموذج LSTM على وحدات خاصة تعرف بالخلايا (Cells)، والتي

تحتوي بوابات التنظيمية تضم بوابة الإدخال (Input Gate)، و بوابة النسيان (Forget Gate)، و بوابة الإخراج (Output Gate)، حيث تتحكم هذه البوابات في تدفق المعلومات وتحديث الذاكرة الداخلية للشبكة أثناء عملية التعلم.

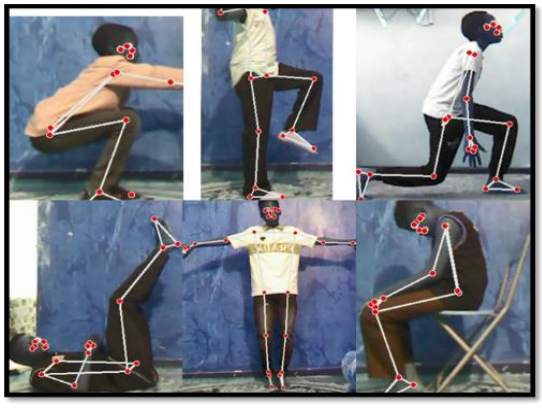
وقد أثبتت شبكات LSTM كفاءة عالية في العديد من التطبيقات، مثل معالجة اللغة الطبيعية، والتعرف على الكلام، وتحليل السلاسل الزمنية، بالإضافة إلى التعرف على الحركات البشرية باستخدام بيانات الهيكل العظمي (Skeleton Data) ، نظرا لقدرتها على تعلم الأنماط الزمنية المعقدة وتحليل تسلسل الحركة بدقة عالية [12] [13]. في هذه الدراسة، تم الاعتماد على نموذج LSTM لتحليل البيانات الحركية المتسلسلة الناتجة عن تتبع المفاصل البشرية، بهدف التمييز بين الحركات الصحيحة والخاطئة اعتمادا على العلاقات الزمنية بين الإطارات المتتابعة.

3. المنهجية المقترحة

تستند المنهجية المقترحة في هذه الدراسة على بناء إطار عمل متكامل لتحليل وتصنيف الحركات البشرية باستخدام بيانات هيكلية تم جمعها بواسطة كاميرا Kinect في بيئة واقعية. تضمنت المنهجية عدة مراحل مترابطة تبدأ بجمع البيانات واستخراج المفاصل الحركية، ثم إجراء عمليات المعالجة المسبقة واستخراج الخصائص، انتهاء إلى بناء نموذج التعلم العميق القائم على شبكة الذاكرة طويلة–قصيرة المدى (LSTM) لتصنيف الحركات إلى حركات صحيحة وأخرى خاطئة.

1.4 تجميع البيانات

تم جمع البيانات الحركية باستخدام كاميرا Kinect، حيث تم تسجيل مجموعة من الحركات البشرية (6 حركات) لعدد من المشاركين في ظروف واقعية. تضمنت البيانات حركات صحيحة وأخرى خاطئة بهدف تدريب النموذج على التمييز بين أنماط الأداء المختلفة. اعتمدت عملية التسجيل على التقاط الإحداثيات ثلاثية الأبعاد للمفاصل الهيكلية للجسم عبر الزمن، مما وفر تسلسلات حركية تمثل الحركة البشرية بصورة ديناميكية. لكل حركة لزيادة تنوع البيانات وتقليل التأثير الفردي بين المشاركين. الشكل (2) يبين الحركات و تمثيلها. تم تسجيل 216 تسلسل حركي تتضمن 108 حركة غير صحيحة Incorrect و 108 حركة صحيحة Correct.



الشكل 2: تسجيل حركات وتمثيلها باستخدام كاميرا Kinect

- In-line Lunge - Leg Raise - Shoulder Abduction - Sit- to stand
Deep Squat - Hurdle Step

2.4 استخراج النقاط الهيكلية

بعد الانتهاء من عملية التسجيل، تم استخراج النقاط الهيكلية (Skeleton Key-points) لكل إطار زمني باستخدام واجهات Kinect البرمجية. تمثل هذه النقاط مواقع المفاصل الأساسية في جسم الإنسان مثل: الرأس – الكتفين – المرفقين – الركبتين – القدمين. الجدول (1) يوضح عينة من البيانات المسجلة. تم تمثيل كل مفصل باستخدام إحداثيات ثلاثية الأبعاد: X, Y, (Z) مما أتاح تكوين تمثيل زمني كامل للحركة البشرية.

الجدول 1: عينة من البيانات المجمعة

J1_Z	J1_Y	J1_X	Frame
-0.52299	0.267938	0.526	1
-0.64088	0.389374	0.526095	2
-0.66942	0.424522	0.526258	3
-0.68226	0.484341	0.523425	4
-1.0643	0.534243	0.518425	5

3.4 معالجة المسبقة للبيانات

قد تحتوي البيانات المجمعة في البيئات الواقعية على ضوضاء واختلافات في طول الحركات، فقد تم تطبيق مجموعة من خطوات المعالجة المسبقة بهدف تحسين جودة البيانات قبل إدخالها إلى النموذج. شملت هذه المرحلة:

-

1- إزالة القيم الغير صالحة أو المفقودة
2- توحيد عدد الإطارات الزمنية بين العينات
3- تنظيم البيانات في شكل متسلسلات زمنية

كما تم تحويل البيانات إلى تمثيل نسبي (Relative Representation) باستخدام مفصل مرجعي ثابت، بهدف تقليل تأثير اختلاف مواقع الأشخاص أثناء التسجيل.

4.4 استخراج الخصائص الحركية

بعد الانتهاء من تجهيز البيانات، تم استخراج مجموعة من الخصائص الحركية المهمة التي تساعد النموذج على فهم طبيعة الحركة البشرية بصورة أفضل. تضمنت الخصائص: (زوايا المفاصل- المسافات بين المفاصل- التغيرات الزمنية للحركة -الخصائص الحركية المتتابعة عبر الفترة الزمنية). وقد ساهمت هذه الخصائص في تحسين قدرة النموذج على التمييز بين الأداء الصحيح والخاطئ للحركة. الشكل (3) يوضح توصيف الحركات و ربطها بالخصائص المستخرجة.



شكل 3: يوضح توصيف الحركات والنتائج المستخرجة

لتقليل فرط التكيف Overfitting و تحسين قدرة النموذج على التعميم، تم تطبيق (Data Augmentation) لزيادة عدد العينات عن طريق إنشاء نسخة واحدة معدلة لكل عينة أصلية. وبذلك ارتفع عدد العينات المستخدمة في تدريب واختبار النموذج إلى432 عينة.

4. بناء النموذج المقترح

تم تصميم نموذج التعلم العميق باستخدام شبكة الذاكرة طويلة–قصيرة المدى LSTM، وذلك لقدرتها العالية على معالجة البيانات الزمنية

المتسلسلة والاحتفاظ بالمعلومات المهمة عبر الزمن. تكون النموذج من:

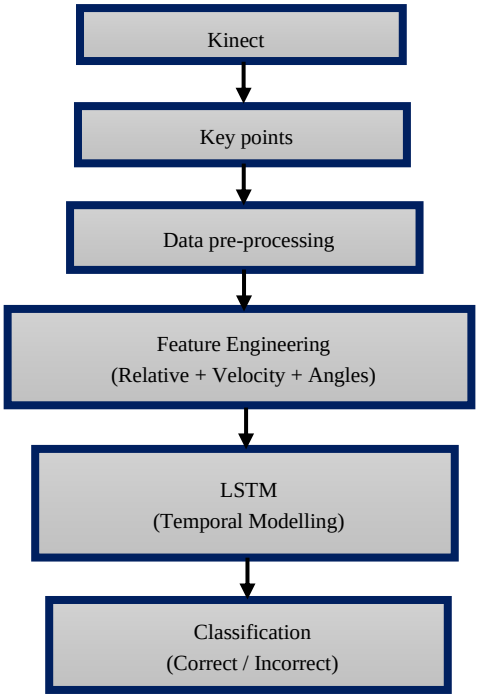
- طبقة إدخال لاستقبال التسلسلات الزمنية للحركة.
- طبقة LSTM لاستخلاص العلاقات الزمنية بين الإطارات.
- طبقة Dropout لتقليل ظاهرة فرط التعلم (Overfitting).
- طبقة Dense لاستخلاص التمثيلات النهائية.
- طبقة إخراج باستخدام دالة تنشيط Sigmoid للتصنيف الثنائي حيث تشير القيم القريبة من 1 الى حركة صحيحة و القريبة من صفر الى حركة غير صحيحة.

إعدادات التدريب (Training Configuration)

تم تدريب النموذج باستخدام مجموعة من الإعدادات المناسبة لتحقيق التوازن بين سرعة التعلم واستقرار الأداء، حيث تم استخدام:

1. عدد حقب التدريب ((Epochs)يساوى 30.
2. حجم الدفعة (Batch Size) يساوى 8.
3. خوارزمية Adam للتحسين.
4. دالة Binary Cross-Entropy لحساب الخسارة.

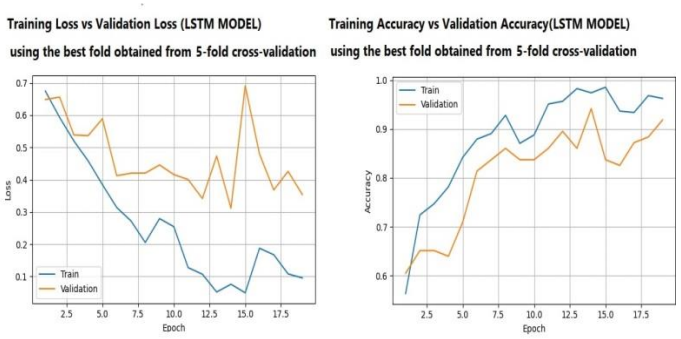
تم تقييم أداء النموذج باستخدام طريقة Stratified 5-Fold Crossvalidation و تم تسجيل مقاييس اداء النموذج التالية: الدقة (Accuracy) - Precision - Recall - F1-score. الشكل (4) يوضح مخطط النموذج المقترح.



الشكل 4: المخطط الانسيابي للنموذج المقترح

5. النتائج و المناقشة

يهدف هذا القسم إلى عرض وتحليل نتائج النموذج المعتمد على شبكة LSTM لتصنيف الحركات البشرية باستخدام بيانات هيكلية تم جمعها بواسطة كاميرا Kinect في بيئة واقعية. تم تقييم أداء النموذج باستخدام مجموعة من مقاييس التقييم القياسية بهدف قياس قدرة النموذج على التمييز بين الحركات الصحيحة والخاطئة ومدى قابليته للتعميم عند التعامل مع بيانات واقعية محدودة. من الشكل (5)، تظهر النتائج تحسنا تدريجي في أداء النموذج خلال الحقب التدريبية، حيث انخفضت قيمة الخسارة (Loss) بشكل واضح مع ارتفاع دقة التصنيف بالشكل تدريجي، مما يشير إلى قدرة النموذج على تعلم الأنماط الزمنية للحركة البشرية بكفاءة. كما أظهرت منحنيات التدريب والتحقق تقارب واضح دون وجود فجوة كبيرة بينهما، وهو ما يدل على استقرار عملية التدريب وعدم تعرض النموذج إلى فرط تعلم (Overfitting) بشكل مؤثر.



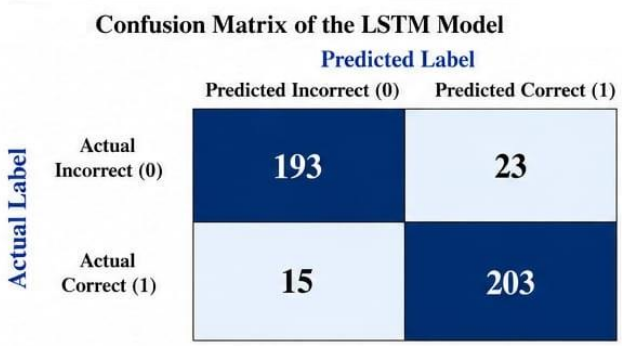
الشكل 5: منحنيات التدريب و الخسارة للنموذج LSTM

يوضح الجدول (2) نتائج تقييم أداء النموذج باستخدام اربع مقاييس.

الجدول 2: نتائج أداء النموذج LSTM باستخدام 5-Fold-Cross-Validation

المقياس	النسبة	الانحراف المعياري
Accuracy	%91.20	4.32%
Precision	%91	%5±
Recall	%89	%5±
F1-score	%90	%4±

تشير هذه النتائج إلى قدرة النموذج على تقديم أداء متوازن في تصنيف الحركات الصحيحة والخاطئة رغم محدودية البيانات المستخدمة. تشير مقاييس تقيم النموذج LSTM ويظهر توزان أداء النموذج عبر جميع المقاييس مما يدل على قدرة تصنيف قوية بين الحركات الواقعية. أظهرت النتائج أن النموذج حافظ على أداء مستقر عبر مختلف تقسيمات البيانات، حيث بلغ متوسط الدقة 91.20% مع انحراف معياري ±4.32%. كما حققت مقاييس Precision وRecall وF1-score مستقرة مع انحراف معياري منخفض نسبيا، مما يعكس قدرة النموذج على التعميم والتعامل مع البيانات بكفاءة. يبين الشكل (6) مصفوفة الالتباس للنموذج LSTM. قام النموذج بتصنيف 23 حركة خاطئة على انها صحيحة من أجمالي 216 حركة خاطئة. كذلك اسند 15 حركة صحيحة فقط من أجمالي 218 حركة صحيحة الى فئة الحركات الخاطئة . تعكس هذه النتائج قدرة النموذج على تحديد الحركات الخاطئة بدقة عالية.



الشكل 6 : مصفوفة الالتباس للنموذج LSTM

1.6 مقارنة بين LSTM و ConvLSTM

يبين الجدول (3) **نتائج** أداء النموذج Conv-LSTM باستخدام 5-Fold-Cross-Validation. من الواضح تفوق نموذج LSTM على Conv-LSTM بفارق كبير. على سبيل المثال، سجل نموذج LSTM متوسط دقة 91.20%

وفي المقابل وصلت متوسط دقة تصنيف الحركات لنموذج Conv-LSTM 58.40%. يوضح الشكل (7) الفرق في مستويات منحنيات الأداء بين النموذجين. تظهر النتائج أن نموذج LSTM حقق أداء أفضل عند التعامل مع البيانات الواقعية المحدودة، في حين كان أداء ConvLSTM أقل استقرار بسبب اعتماده على تمثيلات مكانية–زمنية أكثر تعقيدا تتطلب عادة حجم بيانات أكبر للاستفادة الكاملة من قدراته. تشير هذه النتائج إلى أن النماذج الأبسط زمنيا قد تكون أكثر كفاءة عند التعامل مع مجموعات البيانات الصغيرة نسبيا مقارنة بالنماذج المكانية–الزمنية الأكثر تعقيدا. كما تشير النتائج إلى أن النموذج المقترح استطاع التعرف على الأنماط الزمنية للحركة البشرية بكفاءة عالية رغم محدودية البيانات والضوضاء الناتجة عن ظروف التسجيل الواقعية. ويعود ذلك إلى عدة عوامل، أهمها:

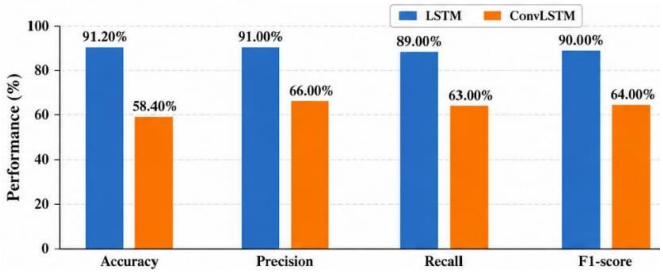
1- استخدام التمثيل النسبي للمفاصل، مما ساعد على تقليل تأثير اختلاف مواضع الأشخاص أثناء التصوير.
2- استخراج الخصائص الزمنية المهمة للحركة البشرية.
3- ملاءمة نموذج LSTM لمعالجة البيانات الزمنية الصغيرة نسبيا.

الجدول 3: نتائج أداء النموذج Conv-LSTM باستخدام 5-Fold-Cross-Validation

المقياس	النسبة
Accuracy	%58.40
Precision	%66
Recall	%63
F1-score	%64

كما أظهرت المقارنة مع نموذج ConvLSTM أن زيادة تعقيد المعمارية لا تعني بالضرورة الحصول على أداء أفضل، خاصة عند التعامل مع بيانات واقعية محدودة الحجم. إذ تتطلب النماذج المكانية–الزمنية عادة بيانات أكبر وأكثر تنوع لتحقيق أداء مرتفع.

وبناء على ذلك، يمكن القول إن اختيار النموذج المناسب يجب أن يعتمد على طبيعة البيانات وخصائصها وليس على تعقيد النموذج فقط، حيث أظهر نموذج LSTM قدرة أعلى على التعميم والاستقرار مقارنة بنموذج ConvLSTM في هذه الدراسة. كما تشير النتائج إلى إمكانية استخدام النموذج المقترح في تطبيقات إعادة التأهيل الحركي، ومراقبة الأداء البدني، والأنظمة الذكية لتحليل الحركة البشرية في البيئات الواقعية منخفضة التكلفة.



الشكل 7: يوضح الفرق في منحنيات الأداء بين النموذجين

6. الاستنتاجات و الأعمال المستقبلية

هدفت هذه الدراسة إلى تطوير إطار عمل يعتمد على تقنيات التعلم العميق لتصنيف الحركات البشرية الصحيحة والخاطئة باستخدام بيانات هيكلية تم جمعها بواسطة كاميرا Kinect في بيئة واقعية. وقد تم بناء نموذج قائم على شبكة الذاكرة طويلة–قصيرة المدى (LSTM) لمعالجة التسلسلات الزمنية للحركة البشرية وتحليل الخصائص الحركية المستخرجة من المفاصل الهيكلية. أظهرت النتائج أن النموذج المقترح حقق أداء عالي في تصنيف الحركات البشرية، حيث بلغت دقة التصنيف (91.20%) مع قيم مرتفعة لمقاييس Precision و Recall وF1-score، مما يشير إلى قدرة النموذج على التعميم والتعامل مع البيانات الواقعية المحدودة بكفاءة. كما أوضحت الدراسة أن استخدام التمثيل النسبي للمفاصل واستخراج الخصائص الزمنية ساهم بشكل واضح في تحسين جودة التنبؤ وتقليل تأثير اختلاف مواقع الأشخاص أثناء التصوير. من خلال المقارنة مع النموذج ConvLSTM، تبين أن نموذج LSTM كان أكثر ملاءمة للبيانات الواقعية الصغيرة، في حين أن النماذج المكانية–الزمنية الأكثر تعقيدا تتطلب عادة بيانات أكبر وأكثر تنوع للاستفادة الكاملة من قدراتها. وتشير هذه النتيجة إلى أن اختيار النموذج المناسب يعتمد على طبيعة البيانات وخصائصها و ليس على تعقيد المعمارية فقط. تؤكد هذه الدراسة إمكانية استخدام النماذج الزمنية الخفيفة في تطبيقات تحليل الحركة البشرية منخفضة التكلفة، خاصة في مجالات إعادة التأهيل الحركي، والطب الرياضي، ومراقبة الأداء البدني في البيئات الواقعية.

1.7 الأعمال المستقبلية

يمكن تطوير هذه الدراسة من خلال:

1- زيادة حجم البيانات المجمعة وتوسيع عدد المشاركين والحركات المختلفة .
2- استخدام عدة زوايا تصوير لتحسين دقة تتبع الحركة .
3- دمج مخرجات وحدات القياس بالقصور الذاتي Inertial Measurement Unit (IMU) و البيانات العضلي لبناء نظام عالي الدقة.
4- اختبار نماذج هجينة تجمع بين الخصائص الزمنية والمكانية بصورة أكثر كفاءة .
5- تطوير نظام ذكي لحظي (Real-Time System) لتقييم الأداء الحركي أثناء التنفيذ المباشر .
6- دراسة تأثير الضوضاء والبيئات المختلفة على أداء نماذج التعلم العميق في تحليل الحركة البشرية.

7. المراجع

[1]- J. K. Aggarwal and M. S. Ryoo, “Human activity analysis: A review,” ACM Computing Surveys, vol. 43, no. 3, pp. 1–43, 2011.
[2]- J. Shotton, A. Fitzgibbon, M. Cook, T. Sharp, M. Finocchio, R. Moore, A. Kipman, and A. Blake, “Real-time human pose recognition in parts from single depth images,” in Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR), 2011, pp. 1297–1304.
[3]- B. Açış and S. Güney, “Classification of Human Movements by Using Kinect Sensor,” International Journal of Intelligent Systems and Applications in Engineering, vol. 10, no. 2, pp. 210–217, 2022.
[4]- C. Li, P. Wang, S. Wang, Y. Hou, and W. Li, “Seq2Seq Model for Human Action Recognition Based on Skeleton and Bidirectional LSTM,” IEEE Access, vol. 7, pp. 123380–123391, 2019.
[5]- A. Ismail-Fawaz, M. Devanne, S. Berretti, J. Weber, and G. Forestier, “Deep Learning for Skeleton-Based Human Motion Rehabilitation Assessment,” Pattern Recognition Letters, vol. 170, pp. 12–20, 2023.
[6]- J. Liu, A. Shahroudy, D. Xu, and G. Wang, “Spatio-Temporal LSTM with Trust Gates for 3D Human Action Recognition,” in Proceedings of the European Conference on Computer Vision (ECCV), 2016, pp. 816–833.

Kinect Data. In 2026 IEEE 16th Symposium on Computer Applications & Industrial Electronics, (ISCAIE) 2026.

[11]- F. Frangoudes, M. Matsangidou, E. C. Schiza, K. Neokleous and C. S. Pattichis, "Assessing Human Motion During Exercise Using Machine Learning: A Literature Review," in *IEEE Access*, vol. 10, pp. 86874-86903, 2022.

[12]- S. Hochreiter and J. Schmidhuber, "Long short-term memory," Neural Computation, vol. 9, no. 8, pp. 1735–1780, 1997.

[13]- Van Houdt, G., Mosquera, C., & Nápoles, "GA review on the long short-term memory model". Artificial intelligence review, 53(8), 5929-5955. 2020.

[7]- M. Shayestegan, J. Kohout, K. Trnková, M. Chovanec, and J. Mareš, "Dual-Head Attentional Transformer-LSTM for Human Activity Recognition," IEEE Access, vol. 12, pp. 44521–44535, 2024.

[8]- Çalışkan A. Detecting human activity types from 3D posture data using deep learning models. Biomedical signal processing and control. 2023.

[9]- Acorn E, Dipsis N, Pincus T, Stathis K. Sit-to-stand movement recognition using kinect. InInternational Symposium on Statistical Learning and Data Sciences 2015 Apr 3 (pp. 179-192). Cham: Springer International Publishing.

[10]- AlQurashi Z, Albahri B, Tahir NM. Comparative Analysis of LSTM and RBF Networks for ASD Gait Classification Using