

التنبؤ بالنشاط البشري باستخدام تقنيات التعلم العميق

بدر نجيب عويدات ، جامعة الزيتونة ، علوم الحاسوب ، ترهونة ، ليبيا ، Bader_najep@yahoo.com
 نجيب احمد خليفة ، جامعة الزيتونة ، علوم الحاسوب ، ترهونة ، ليبيا ، najibhass@yahoo.com
 علي محمد فرج ، جامعة الزيتونة ، علوم الحاسوب ، ترهونة ، ليبيا ، aliabumrfg@yahoo.com

ومن خلال دراسة النتائج وتحليلها، يمكن أن يقدم البحث مساهمة قيمة في تطوير التطبيقات الذكية وتحسين جودة حياة الأفراد وفهم أعمق لأنماط السلوك البشري.

فعدت دراسة البيانات ومعرفة نوع النشاط، يمكن الحصول على العديد من المعلومات المفيدة والمتعلقة بنوعية النشاط وطريقة تنفيذه. بعض هذه المعلومات تشمل:

1. معدل الحركة: يمكن تحديد معدل الحركة لكل نشاط بناءً على قراءات محسسات التسارع في المحاور الثلاثة. على سبيل المثال، يمكن معرفة ما إذا كان الشخص يمشي بسرعة ثابتة أو يقوم بالركض بسرعة عالية.
2. نوعية الحركة: يمكن التعرف على نوع النشاط بناءً على القيم المقروءة لمحسسات التسارع. على سبيل المثال، يمكن تمييز بين المشي والجري وصعود السلالم ونزولها بناءً على نمط الحركة والتغيرات في التسارع.
3. مدة النشاط: يمكن تقدير مدة كل نشاط بناءً على الفترة الزمنية التي تم جمع البيانات خلالها. هذا يساعد في فهم مدى استمرارية النشاط ومدى تأثيره على الجسم.
4. توزيع النشاط: يمكن تحليل توزيع النشاط على مدار اليوم وتحديد الفترات الزمنية التي تكثر فيها أو تقل فيها الأنشطة المختلفة، مما يمكن أن يساعد في تطوير خطط التمرين أو تقييم نمط الحياة الصحي.
5. تأثير النشاط على الصحة: يمكن استخدام البيانات لفهم تأثير النشاط البدني على الصحة العامة، مثل تقدير السرعات الحرارية المحروقة أثناء ممارسة النشاط، أو تحليل الأنماط الحركية وتأثيرها على معايير الصحة مثل معدل ضربات القلب والتنفس.

2. الأعمال السابقة

في دراسة علوانة وآخرون [1] تم استخدام أربع مجموعات بيانات والتي تأخذ في الاعتبار حالات السقوط والتي تشير إلى مجموعة الحركات أو الأنشطة التي تمثل السقوط أو الوقوع على الأرض. يمكن أن تكون حالات السقوط تشمل أنواعاً مختلفة مثل السقوط الناتج عن الانزلاق، أو السقوط الناتج عن فقدان التوازن، أو السقوط الناتج عن الاصطدام بشيء، وما إلى ذلك. مجموعة AF-2 والتي تتضمن ثمانين فئات مختلفة تمثل أنواع وحالات السقوط. وF-8 والتي تتضمن ثمانين فئات مختلفة تمثل أنواع مختلفة من حالات السقوط. وA-9 تتضمن تسع فئات مختلفة تمثل الأنشطة اليومية المختلفة من الأنشطة اليومية. وAF-17 تتضمن سبعة عشر فئة تمثل الأنشطة اليومية وحالات السقوط. وتم استخدام نموذج LSTM النموذج الأول ذو اتجاه واحد (Unidirectional) ويتم تدريب النموذج على متسلسلة البيانات في اتجاه واحد فقط، عادةً من البداية إلى النهاية. والنموذج الثاني ذو اتجاهين (Bidirectional) وفي هذا النوع يتم تدريب النموذج على متسلسلة البيانات في كلا الاتجاهين، أي من البداية إلى النهاية ومن النهاية إلى البداية. يسمح هذا النهج بمزيد من الاستفادة من المعلومات الزمنية المتاحة في تسلسل البيانات. أظهرت النتائج أن النهج ذو الاتجاه الثنائي يحسن قليلاً جودة التعرف على الأنشطة على النهج ذو الاتجاه الواحد. ومع ذلك، يستغرق النهج ذو الاتجاه الثنائي وقتاً أطول أثناء التدريب، مما قد

المخلص—يعتبر التعرف على الأنشطة البشرية (Human Activity Recognition) مجالاً في علم الحوسبة الذي يهتم بتطوير نماذج وتقنيات لتحديد وتصنيف الأنشطة البشرية استناداً إلى بيانات معينة. تأتي هذه البيانات غالباً من أجهزة استشعار مثل أجهزة التسارع (accelerometers) في الهواتف الذكية أو الأجهزة القابلة للارتداء، والتي تقيس الحركة والتسارع والسرعة للأفراد. تعتبر هذه البيانات سلاسل زمنية لقياس نشاط الإنسان، حيث تحتوي على معلومات مثل المستخدم، نشاط الإنسان، التسجيل الزمني (timestamp)، وقيم لمحاور مختلفة (x-axis، y-axis، z-axis) والتي تمثل قراءات الحساسات الموجودة على الجهاز المستخدم لقياس الحركة. تم جمع مجموعة البيانات المستخدمة في هذا البحث من مختبر WISDM، قسم علوم الحاسوب والمعلومات، جامعة فورد هام، حيث جمعت هذه البيانات من 36 مستخدماً مختلفاً أثناء أدائهم لبعض الأنشطة البشرية الشائعة مثل المشي، والركض، وصعود السلالم، ونزول السلالم، والجلوس، والوقوف لفترات زمنية محددة. في هذا البحث، تم مقارنة استخدام ثلاثة نماذج مختلفة لتنبؤ بالنشاط البشري باستخدام مجموعة بيانات WISDM. تشمل النماذج المستخدمة نموذج Convolutional Neural Network (CNN) مع طبقة تحويل زمني (Temporal Convolution Layer)، ونموذج LSTM مع نسبة Dropout أعلى، ونموذج LSTM مع نسبة Dropout أقل. يُظهر التحليل الشامل لنتائج دراسة التعرف على الأنشطة البشرية باستخدام مجموعة بيانات WISDM أن النموذج LSTM مع نسبة Dropout أقل حقق أداءً متفوقاً بشكل ملحوظ على النماذج الأخرى المدروسة. بعد التدريب والتقييم، حقق هذا النموذج دقة تصنيف بلغت 0.9644 على بيانات التحقق، مما يشير إلى قدرته على تحديد وتصنيف الأنشطة البشرية بدقة عالية. حيث تتضح جودة أداء النموذج من خلال قيم الدقة والخسارة التي تحسنت بشكل ملحوظ خلال عملية التدريب، مما يدل على فعالية عملية التعلم للنموذج.

الكلمات المفتاحية— النشاط البشري، التعلم العميق، أجهزة التسارع، الهواتف الذكية، التسجيل الزمني.

1. المقدمة

في ظل التطورات الهائلة في مجال تكنولوجيا المعلومات والاتصالات، أصبحت أجهزة الهواتف الذكية والأجهزة القابلة للارتداء شركاء بشكل يومي للأفراد، ترافقهم في مختلف نشاطات حياتهم. ومع تزايد استخدام هذه الأجهزة، أصبحت بيانات الحركة والتسارع التي تُسجلها أجهزة التسجيل المدمجة بها تحمل قيمة هائلة في فهم النشاطات البشرية وتحليلها. يعد التنبؤ بالنشاط البشري باستخدام تقنيات التعلم العميق مجالاً بحثياً حيوياً ومنظوراً، يتيح فرصاً متعددة لتطوير تطبيقات مبتكرة تخدم مجموعة واسعة من الصناعات والقطاعات. بفضل قدرة هذه التقنيات على تحليل وتفسير البيانات الضخمة بسرعة ودقة، يمكن أن يسهم التنبؤ بالنشاط البشري في تحسين العديد من المجالات، بما في ذلك الرعاية الصحية، واللياقة البدنية، والأمن، وتجارب المستخدم، والتحليلات السلوكية، وغيرها.

وبناءً على هذا الإطار، يسعى هذا البحث إلى استكشاف ومقارنة النماذج العميقة المختلفة لتنبؤ النشاط البشري، وذلك باستخدام مجموعة بيانات WISDM. يهدف البحث إلى تحليل أداء كل نموذج وتحديد الأكثر فعالية في التنبؤ بالنشاط البشري، مما يمهد الطريق لتطبيقات عملية قابلة للتطبيق على نطاق واسع في حياة الأفراد والمجتمعات.

استلمت الورقة بالكامل في 14 ابريل 2024 وروجعت في 08 مايو 2024
 وقبلت للنشر في 15 مايو 2024
 ونشرت ومتاحة على الشبكة العنكبوتية في 08 أغسطس 2024.

A-9: 91.2%, AF-17: 83.31%			
UCI: 96.71%, WISDM: 95.86%	مع Bi-LSTM آلية الانتباه	UCI ، WISDM	بين شياوتشون (2022)
92%	مع تقنية التطبيع الدفعي (BN)	غير محدد	زيبين وأخرون (2018)


3. المواد وطرق العمل

تم استخدام مجموعة بيانات النشاط البشري WISDM من كاكل (Kaggle) لتدريب ثلاثة نماذج عميقة. تم استخدام مكتبة Keras للتعلم العميق لبناء النماذج ومكتبة seaborn+Matplotlib للرسم البيانية. وفق المعاملات كما في الجدول 2 كالتالي:

جدول 2: المعاملات الفائقة للنماذج.

القيمة	المعامل الفائق
42	البذرة العشوائية (random seed)
50	الخطوات الزمنية (time steps)
10	الخطوة (step)
3	عدد الميزات (features)
6	عدد الفئات (classes)
50	عدد العورات التدريبية (epochs)
1024	حجم الدفعة (batch size)
0.0025	معدل التعلم (learning rate)
0.0015	قيمة الخسارة (L2 (l2_loss)

بدأت خطوات البحث المتبعة في هذه الدراسة بجمع البيانات ومعالجتها واستكشافها لفهمها بشكل أعمق. بعد ذلك، تم تقسيم البيانات وتدريب نموذج التعلم الآلي، تلاها عملية تقييم النموذج وضبطه لتحقيق أفضل أداء ممكن. أخيراً، تم عرض النتائج بشكل ملائم للتحليل والتفسير. الشكل 1 يوضح مخطط تدفق العمليات التي اتبعت لتحقيق أهداف البحث.



الشكل 1: خطوات البحث

4. مجموعة البيانات

في هذا البحث، تم استخدام مجموعة بيانات النشاط البشري WISDM، والتي جُمعت من قبل 36 مستخدماً مختلفاً خلال مشاركتهم في أنشطة بشرية شائعة. تم الحصول على مجموعة بيانات WISDM من موقع Kaggle، والتي توفرها مختبر WISDM في قسم علوم الكمبيوتر والمعلومات بجامعة فورد هام في نيويورك. تشمل الأنشطة التي تم تسجيلها المشي (Walking)، الركض (Jogging)، صعود السلالم (Upstairs)، نزول السلالم (Downstairs)، الجلوس (Sitting)، والوقوف (Standing). تم تسجيل البيانات باستخدام مستشعرات تسارع ثلاثية الأبعاد على محاور x، y، z، بالإضافة إلى تسجيل الفترات الزمنية باستخدام Unix timestamp.

تحتوي البيانات على 6 سمات ولا توجد قيم مفقودة في السمات. وكان توزيع الفئات في مجموعة البيانات كما يلي:

المشي (Walking) = 424,400 عينة ما يمثل من مجموعة البيانات نسبة (38.6%).

الجري (Jogging) = 342,177 عينة ما يمثل من مجموعة البيانات نسبة (31.2%).

صعود الدرج (Upstairs) = 122,869 عينة ما يمثل من مجموعة البيانات نسبة (11.2%).

نزول الدرج (Downstairs) = 100,427 عينة ما يمثل من مجموعة البيانات نسبة (9.1%).

يعيق تطبيقه على مجموعات بيانات كبيرة. وكانت نتائج النموذج الأول ذو اتجاه واحد (Unidirectional) على مجموعات البيانات AF-2 و F-8 و A-9 و AF-17 وكانت نسبة الدقة على التوالي 98.87% و 73.46% و 90.25% و 80.59% وكانت نتيجة النموذج الثاني ذو اتجاهين (Bidirectional) على مجموعة البيانات على التوالي 99.25% و 74.89% و 91.2% و 83.31%. مع اختلاف عدد الحقب (Epochs) والتكرار (Iterations) وعدد العينات (batch size) لكل مجموعة بيانات مع تساوي قيم معدل التعلم (Learning rate) والطبقات المخفية (Hidden units) ودالة التسريب (Dropout) لكل مجموعات البيانات الأربعة.

استخدم بحث بين شياوتشون [2] نموذج جديد يعتمد على الشبكات العصبية التكرارية ثنائية الاتجاه (Bi-LSTM) مع آلية الانتباه (Attention mechanism) لتعرف على الأنشطة البشرية باستخدام البيانات التي تتضمن ضوضاء وبيانات مفقودة. وكان التحدي الرئيسي الذي ركز عليه البحث هو زمن التصنيف ودقته عند معالجة عينات السلسلة ذات التبعية الطويلة مع البيانات التي تتضمن ضوضاء أو قيم مفقودة. تقوم الطريقة المقترحة بتقسيم الميزات الأصلية من أجهزة الاستشعار إلى أقسام فرعية باستخدام نافذة تحرك متزامنة، وتُغذى إلى طبقة متوازنة تعتمد على شبكات CNN و Bi-LSTM لتسريع استخراج الميزات مع البيانات التي تتضمن بيانات مفقودة أو ضوضاء. يتم إعادة توزيع أوزان الميزات المستخرجة باستخدام آلية الانتباه ودمجها في ميزات كاملة. في النهاية، يتم الحصول على نتائج التصنيف النهائية باستخدام الطبقة الكاملة. تم تقييم أداء الطريقة المقترحة على مجموعة بيانات الأنشطة البشرية العامة UCI و WISDM و أظهرت النتائج أن النموذج المقترح يفوق النماذج الحالية من حيث دقة التصنيف (96.71%) على مجموعة بيانات UCI ودقة تصنيف (95.86%) على مجموعة بيانات WISDM وتعقيد الوقت الحسابي (أسرع بمقدار 1.1 في كل دقيقة على الأقل).

تقترح دراسة تهمينا زيبين وأخرون [3] استخدام نموذج LSTM العميق يمكنه معالجة إشارات البيانات الخام دون الحاجة إلى ميزات محددة مسبقاً، ويحقق دقة متوسطة بنسبة 92% في تصنيف الأنشطة البشرية الستة. تظهر النتائج أن الأنشطة ذات التباين الزمني، مثل المشي على المستوى والصعود والهبوط، تستفيد بشكل كبير من معالجة الذاكرة LSTM لتحقيق تصنيف دقيق بنسبة تزيد عن 95%. وبينت الدراسة أن النموذج LSTM يواجه صعوبة في تصنيف الأنشطة الثابتة مثل الجلوس والوقوف، نظراً لاحتوائها على أقل تباين زمني وعناصر متكررة، مما يقلل من قدرة النموذج على استخراج الأنماط الزمنية. حيث تظهر النتائج أن استخدام تقنية تطبيع الدفع (BN) خلال التدريب يعزز أداء النموذج LSTM، حيث يحقق النموذج المعتمد على BN دقة 92%، مقارنة بـ 88% للنموذج بدون BN، وذلك بمعالجة إشارات البيانات الخام مع زيادة في السرعة بعدد أربع مرات في عملية التدريب.

التعليق على الدراسات السابقة:

تشابهت الدراسة الحالية مع دراسة علاونة وآخرين في استخدام نماذج LSTM العميقة للتعرف على النشاط البشري، لكنها اختلفت في هياكل النماذج. استخدمت الدراسة الحالية نموذجين مختلفين في دالة التسريب، بينما استخدمت الدراسة السابقة نموذجين أحدهما ذو اتجاه واحد والآخر ذو اتجاهين. كما أن الدراسة السابقة اعتمدت على عدد أكبر من مجموعات البيانات، مما زاد من تنوع النتائج وموثوقية النماذج. من جهة أخرى، استخدمت دراسة بين شياوتشون مجموعتي بيانات ونموذج Bi-LSTM مع آلية الانتباه، مركزة على تعقيد الوقت الحسابي. في المقابل، اعتمدت الدراسة الحالية على مجموعة بيانات واحدة وثلاثة نماذج عميقة دون التركيز على تعقيد الوقت الحسابي، وكانت النتائج متقاربة بين الراسيتين. أما في دراسة تهمينا زيبين وآخرين، فقد تم استخدام نموذجين LSTM بتقنيات مختلفة. بينما في الدراسة الحالية، استخدمت نموذجين LSTM بمعدلات تسريب مختلفة، وأظهرت نتائج أعلى من النتائج السابقة. كما تميزت الدراسة الحالية بإضافة نموذج ثالث من نوع CNN لتعزيز موثوقية النتائج.

جدول 1: ملخص الدراسات السابقة.

الدراسة	مجموعة البيانات	تقنية التصنيف	دقة التصنيف
دراسة علاونة وآخرون (2020)	AF-2 ، F-8 ، A-9 ، AF-17	نموذج الذاكرة القصيرة الطويلة ذو اتجاه واحد، نموذج الذاكرة القصيرة الطويلة ذو اتجاهين	ذو الاتجاه الواحد : AF-2: 98.87%, F-8: 73.46%, A-9: 90.25% , AF-17: 80.59% :ذو الاتجاهين AF-2: 99.25%, F-8: 74.89%,

x-accel: نوع البيانات رقمي (numeric)، نفس مواصفات x-acceleration.
z-accel: نوع البيانات رقمي (numeric)، نفس مواصفات z-acceleration.

البيانات المقدمة عبارة عن سجلات لنشاط الإنسان، تحتوي على المعلومات كما في الجدول 3 كتالي:
جدول 3: بيانات تسارع الأنشطة البشرية.

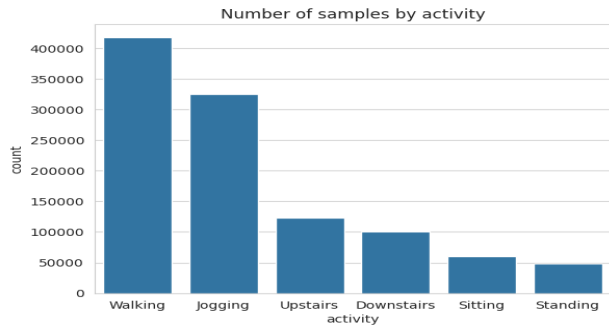
وفي الشكل 2 تمثيل لعينة من مجموعة بيانات WISDM لعدد 100 سجل.

	user activity	timestamp	x-axis	y-axis	z-axis
0	33 Jogging	49105962326000	-0.694638	12.680544	0.50395286;
1	33 Jogging	49106062271000	5.012288	11.264028	0.95342433;
2	33 Jogging	49106112167000	4.903325	10.882658	-0.08172209;
3	33 Jogging	49106222305000	-0.612916	18.496431	3.0237172;
4	33 Jogging	49106332290000	-1.184970	12.108489	7.205164;
..
95	33 Jogging	49116072311000	2.764931	17.352324	7.7363577;
96	33 Jogging	49116122238000	2.342700	15.894946	3.6774938;
97	33 Jogging	49116232315000	4.794363	3.827318	0.9942854;
98	33 Jogging	49116342330000	-1.838747	12.830367	-1.56634;
99	33 Jogging	49116452316000	5.366417	14.410328	6.742072;

[100 rows x 6 columns]

الشكل 2: عينة من مجموعة بيانات WISDM.

كانت النشاطات متفاوتة في مجموعة البيانات كما في الشكل 2، حيث كانت نسبة النشاطات كالمشي والركض أعلى بالمقارنة بباقي الأنشطة مثل صعود السلالم، ونزول السلالم، والجلوس، والوقوف، التي كانت قريبة من بعضها البعض وأقل بنسبة مقارنة بالنشاطات كالمشي والركض. الشكل 3 يُظهر الرسم التوضيحي لتوزيع العينات حسب النشاطات.



الشكل 3: عدد العينات حسب النشاط.

تم استخدام مجموعة بيانات النشاط البشري WISDM من كاكل (Kaggle) وقد تم جمع هذه البيانات من 36 مستخدمًا مختلفًا أثناء قيامهم ببعض الأنشطة البشرية الشائعة مثل المشي، والركض، وصعود السلالم، ونزول السلالم، والجلوس، والوقوف لفترات زمنية محددة. في الشكل 4 تمثيل لعينة من نشاط ثلاثة مستخدمين. تم تقسيم مجموعة البيانات لتحقيق توزيع متوازن وضمان تعميم النموذج. بحيث تم تخصيص 56% من البيانات للتدريب و14% للاختبار و30% للتحقق. هذا النوع من التقسيم يضمن توازن الفئات ويعزز من دقة وموثوقية النموذج.

المستخدم (User)	النشاط (Activity)	الفترة الزمنية (Timestamp)	x-axis	y-axis	z-axis
يحدد هوية الشخص الذي قام بتسجيل البيانات.	يحدد نشاط الإنسان المسجل، مثل المشي (Walking)، الركض (Jogging)، صعود السلالم (Upstairs)، نزول السلالم (Downstairs)، الجلوس (Sitting)، والوقوف (Standing).	يحدد الزمن الذي تم فيه تسجيل البيانات، عادةً بصيغة Unix timestamp	تمثل قراءات التسارع على محور X، الذي يكون عمودياً على الأفق ويتجه إلى اليمين والخلف.	تمثل قراءات التسارع على محور Y، الذي يكون عمودياً على الأفق ويتجه إلى اليمين واليسار.	تمثل قراءات التسارع على محور Z، الذي يكون رأسياً ويتجه لأعلى ولأسفل.

الجلوس (Sitting) = 59,939 عينة ما يمثل من مجموعة البيانات نسبة (5.5%).

الوقوف (Standing) = 48,395 عينة ما يمثل من مجموعة البيانات نسبة (4.4%).

تنسيق البيانات: مجموعة البيانات تتبع هذا التنسيق:

[user],[activity],[timestamp],[x-acceleration],[y-accel],[z-accel]

شكل البيانات: مجموعة البيانات تتبع الشكل:

33,Jogging,49105962326000-6946377, 12.680544, 0.50395286

معدل العينة: في مجموعة بيانات النشاط البشري WISDM هو 20 هرتز، مما يعني أنه تم جمع 20 عينة في الثانية. بعبارة أخرى، يتم تسجيل عينة واحدة كل 50 ملي ثانية (20/1 من الثانية). هذا المعدل يوفر دقة زمنية عالية، مما يسمح بتحليل دقيق لتغيرات الحركة والأنشطة البشرية المسجلة.

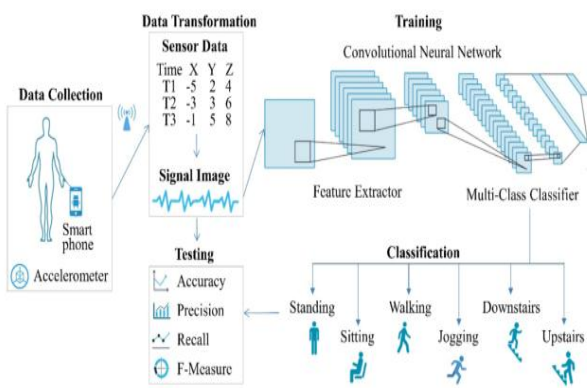
الحقول: في مجموعة بيانات WISDM، هناك عدة حقول تحتوي على معلومات حول الأنشطة المسجلة. هذه الحقول تشمل:

user: نوع البيانات اسمي (nominal)، القيم من 1 إلى 36.
activity: نوع البيانات اسمي (nominal)، القيم هي (Walking, Upstairs, Downstairs, Standing, Sitting, Jogging)
timestamp: نوع البيانات رقمي (numeric)، يمثل وقت تشغيل الهاتف بوحدة النانو ثانية.

x-acceleration: نوع البيانات رقمي (numeric)، قيمه بين -20 و 20. والتي تمثل التسارع في اتجاه x بمقياس التسارع في الهاتف الأندرويد.

القيمة 10 هو $1g = 9.81 \text{ m/s}^2$ تعني أن مقياس التسارع في الهاتف يقيس التسارع بوحدة "g"، حيث أن $1g$ (جاذبية أرضية واحدة) يساوي 9.81 m/s^2 . وبالتالي، قراءة مقياس التسارع 10 تعني تسارعاً قدره 98.1 m/s^2 ، أي $10g$.

القيمة 0 تعني عدم وجود تسارع: إذا كانت قراءة مقياس التسارع تساوي 0، فهذا يعني أن الهاتف لا يتسارع في ذلك الاتجاه، أي لا توجد قوة مؤثرة على الهاتف تجعله يغير سرعته في هذا الاتجاه.



3. Dropout Layer: طبقة تقليل الفرط في التعلم، والتي تقوم بإسقاط (تجاهل) عشوائي لبعض الوحدات في الطبقة السابقة خلال التدريب، وذلك لمنع الوزن من الاعتماد بشكل كبير على الوحدات المجاورة وتحسين عملية التعلم.

4. Flatten Layer: طبقة تقوم بتسطيح البيانات المقدمة إليها لتحويلها من تنسيق ثلاثي الأبعاد إلى تنسيق مسطح (مستوى واحد)، وذلك لتمكين استخدام طبقات متصلة بالكامل.

5. Fully connected layers: طبقات متصلة بالكامل تقوم بتنفيذ العمليات الخطية وتطبيق الوظائف غير الخطية على البيانات المسطحة من أجل تصنيف البيانات.

6. Output layer: طبقة الإخراج التي تستخدم طبقة Softmax لتصنيف البيانات في أكثر من فئة.

الشكل 6: الهيكل العام لنموذج CNN مع طبقة TCL.

ب. نموذج LSTM مع نسبة Dropout أعلى:
ويتكون النموذج كما في الشكل 7 من الطبقات:

1. RNN Layer (LSTM): يستخدم لإنشاء طبقة شبكة عصبية متكاملة مع خلايا LSTM التي تسمح بالتعلم من السلاسل الزمنية والبيانات التسلسلية.

2. Dropout Layer: يستخدم لتطبيق تقنية الإسقاط (Dropout) التي تساعد في منع الزيادة في الإفراط في التعلم من خلال إسقاط عشوائي لبعض الوحدات خلال التدريب.

3. Dense Layer with ReLU Activation: طبقة متصلة بكل الوحدات في الطبقة السابقة (Dropout)، وتستخدم وظيفة تنشيط ReLU لإدخال عناصر غير خطية في النموذج.

4. Softmax Layer: يستخدم لتوليد التوزيعات الاحتمالية للفئات المختلفة في النموذج، مما يساعد في تصنيف البيانات إلى فئات

Layer #	Layer (type)	Output Shape	Param #
1	conv1d (Conv1D)	(None, 48, 64)	640
2	max_pooling1d (MaxPooling1D)	(None, 24, 64)	0
3	dropout (Dropout)	(None, 24, 64)	0
4	flatten (Flatten)	(None, 1536)	0
5	dense (Dense)	(None, 128)	196736
6	dense_1 (Dense)	(None, 64)	8256
7	dense_2 (Dense)	(None, 4)	260

=====
Total params: 205892 (804.27 KB)
Trainable params: 205892 (804.27 KB)
Non-trainable params: 0 (0.00 Byte)

مختلفة.

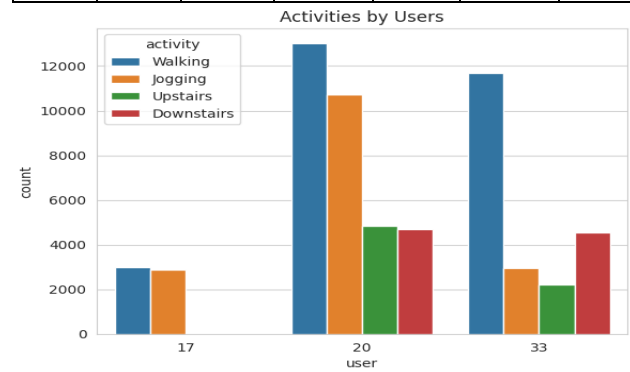
الشكل 7: الهيكل العام لنموذج LSTM مع نسبة Dropout أعلى.

ج. النموذج LSTM مع نسبة Dropout أقل:

ويتكون النموذج كما في الشكل 8 من

1. LSTM Layer: هذه الطبقة تستخدم لإنشاء طبقة من الذاكرة التي تحتفظ بمعلومات من السلسلة الزمنية. تتلقى وتعالج المدخلات المتسلسلة وتنتج مخرجات زمنية.

النشاطات Activities							المحور
Standing	Sitting	Downstairs	Upstairs	Jogging	Walking		
مستقر	مستقر	مستقر	غير مستقر	مستقر	مستقر	x-axis	
مستقر	غير مستقر	مستقر	مستقر	مستقر	مستقر	y-axis	
مستقر	مستقر	مستقر	مستقر	مستقر	مستقر	z-axis	



الشكل 4: الأنشطة حسب المستخدمين.

من خلال التحليل الاستكشافي للبيانات تبين ان مجموعة بيانات تحتوي على 1086466 سجل مقسمة على 36 مستخدم. يوجد سجل واحد معطوب واخر يحتوي على قيم مفقودة، ووجود 11744 سجل يحتوي على عدد غير صحيح من الأعمدة ما نسبته من مجموعة البيانات (1.081%)، وتم استبعادها من التدريب. وجود فواصل منقوطة في العمود z-axis، ولقد تم إزالة كل هذه الفواصل. وجود 12842 سجل يحتوي قيم زمنية غير صحيحة ما نسبته من مجموعة البيانات (1.182%) ولم يتم معالجتها.

ومن خلال نتائج اختبار ديكي فولر الموسع ADF لاختبار استقرار السلاسل الزمنية كانت النتيجة في الجدول 4 التي أظهرت عدم استقرار في نشاط صعود السلالم على المحور x، وعدم استقرار أيضا لنشاط الجلوس على المحور y.

جدول 4: نتائج اختبار ديكي فولر الموسع ADF لاختبار استقرار السلاسل.

5. النماذج المستخدمة في الدراسة

تم استخدام ثلاثة نماذج عميقة للتدريب والاختبار على مجموعة بيانات النشاط البشري WISDM المكونة من 1073623 عينة ذات 6 سمات رئيسية. في الشكل 5 توضيح للمخطط العام لآلية عمل للنماذج العميقة على مجموعة بيانات الأنشطة البشرية:

الشكل 5: سير عمل التعرف على النشاط البشري [4].

أ. نموذج Convolutional Neural Network (CNN):

يتكون النموذج كما في الشكل 6 من الطبقات التالية:

1. Temporal Convolution Layer: طبقة تحويل زمني تستخدم في استخراج الميزات المتعلقة بالزمن من بيانات سريعة التغير مثل الإشارات الصوتية أو الإشارات الزمنية. تُعالج هذه الطبقة الإشارات المتعددة الأبعاد مثل السلاسل الزمنية.

2. MaxPooling Layer: طبقة تقليل الأبعاد التي تقوم بتقليل حجم البيانات المستخدمة وتخفيض التعقيد من خلال تقليل الأبعاد الزمنية.

يتم حساب المتوسط المرجح عن طريق حساب المتوسط الحسابي لقيم المعايير الأدائية (مثل الدقة والاستدعاء و F1 score) عبر كل الفئات باستخدام وزن يعتمد على عدد العينات من خلال المعادلة [6]:

$$\text{Weighted Avg} = \frac{(\text{Metric}_0 * \text{support}_0) + (\text{Metric}_1 * \text{support}_1)}{\text{Total support}} \quad (5)$$

و. مقياس F (F -measure):

$$F1 = \frac{2 * \text{Precision} * \text{recall}}{\text{Precision} + \text{recall}} \quad (6)$$

ز. الدعم ($Support$):

يعبر عن التوزيع الفعلي للعينات عبر الفئات المختلفة، وهو قيمة عددية تساهم في تقييم أداء نموذج التصنيف من خلال تقديم معلومات عن عدد الأمثلة لكل فئة.

7. النتائج

تم بناء الخوارزميات باستخدام لغة برمجة Python وإطار عمل التعلم العميق Keras على منصة Google Colab، والتي تعتبر أداة محاكاة لأجراء التجارب وإنشاء النماذج، وهي متاحة ومجانية للباحثين. حيث تم تدريب ثلاثة نماذج عميقة هي نموذج CNN مع طبقة TCL ونموذج LSTM مع نسبة Dropout أعلى ونموذج LSTM مع نسبة Dropout أقل على مجموعة بيانات WISDM للأنشطة البشرية. تم تقسيم مجموعة البيانات لتحقيق توزيع متوازن وضمان تعميم النموذج، حيث تم تخصيص 56% للتدريب (Training Set)، و30% للاختبار (Test Set)، و14% للتحقق (Validation Set). وقد تم ترميز النشاطات في نتائج النماذج وفقاً للجدول 5 أدناه.

جدول 5: رموز النشاطات في النتائج.

الرمز	النشاط
0	نشاط المشي (Walking).
1	نشاط الركض (Jogging).
2	نشاط صعود السلالم (Upstairs).
3	نشاط نزول السلالم (Downstairs).
4	نشاط الجلوس (Sitting).
5	نشاط الوقوف (Standing).

وكانت نتيجة النماذج كالتالي:

أ. نموذج CNN مع طبقة TCL:


بيانات الاختبار: تم الحصول على نتائج الاختبار وفق الشكل 9 كالتالي:

Accuracy: 0.9513639387890885
Classification Report:

	precision	recall	f1-score	support
0	0.86	0.82	0.84	1482
1	0.97	0.98	0.98	4578
2	0.99	0.98	0.98	845
3	0.98	0.98	0.98	670
4	0.87	0.83	0.85	1643
5	0.97	0.99	0.98	5812
accuracy			0.95	15030
macro avg	0.94	0.93	0.93	15030
weighted avg	0.95	0.95	0.95	15030

الشكل 9: نتائج بيانات التدريب لنموذج CNN.

أعطت مصفوفة الارتباك Confusion Matrix لبيانات الاختبار للنموذج وفق الشكل 10 كالتالي:



الشكل 10: مصفوفة الارتباك لبيانات التدريب لنموذج CNN.

2. Dropout Layer: تقوم بعملية الإسقاط (Dropout) للوحدات المدخلة بنسبة معينة، مما يساعد في منع الزيادة في إفراط التعلم في الفواصل الزمنية المتعلقة بالتحديثات.

3. Dense Layer with ReLU Activation: طبقة كاملة الاتصال تحتوي على وحدات متصلة بالكامل مع وظيفة تنشيط ReLU (Rectified Linear Activation)، والتي تقوم بتعلم التمثيلات المفيدة للبيانات.

4. Dense Layer with Softmax Activation: طبقة كاملة الاتصال تستخدم وظيفة تنشيط Softmax لتحويل النتائج النهائية إلى توزيعات احتمالية، مما يسهل التصنيف النهائي للفئات المختلفة.

Layer (type)	Output Shape	Param #
lstm_3 (LSTM)	(None, 64)	17408
dropout_3 (Dropout)	(None, 64)	0
dense_6 (Dense)	(None, 32)	2080
dense_7 (Dense)	(None, 4)	132

=====
Total params: 19620 (76.64 KB)
Trainable params: 19620 (76.64 KB)
Non-trainable params: 0 (0.00 Byte)

الشكل 8: الهيكل العام لنموذج LSTM مع نسبة Dropout أقل.

6. معايير تقييم الخوارزميات

بعد بناء أحد نماذج خوارزميات التصنيف يتم تطبيق عدة معايير للتأكد من صحة التصنيف ونتائج الخوارزمية ومنها:

أ. نسبة صحة خوارزمية التصنيف ($Accuracy$):

$$Accuracy = \frac{TP+TN}{TP+TN+FP+FN} = \frac{TP+TN}{P+N} \quad (1)$$

حيث ان:

TP = True Positives) وهي السجلات التي تم التنبؤ بفتتها بشكل صحيح.

TN = True Negatives) وهي السجلات التي تم التنبؤ بها بشكل صحيح على انها فئة سالبة.

FP = False Positives) وهي السجلات السالبة التي تنبأ بها النموذج بشكل خاطئ والحقا بالفئة الموجبة.

FN = False Negatives) وهو عدد السجلات الموجبة التي تم اعتبارها بالخطأ سالبة مع أنها موجبة [5].

ب. مقياس المثالية ($Recall$):

هي نسبة السجلات الموجبة التي تم التنبؤ بها وتصنيفها بشكل صحيح إلى كل السجلات الموجبة [6].

$$Recall = \frac{TP}{TP+FN} \quad (2)$$

ج. مقياس الدقة ($Precision$):

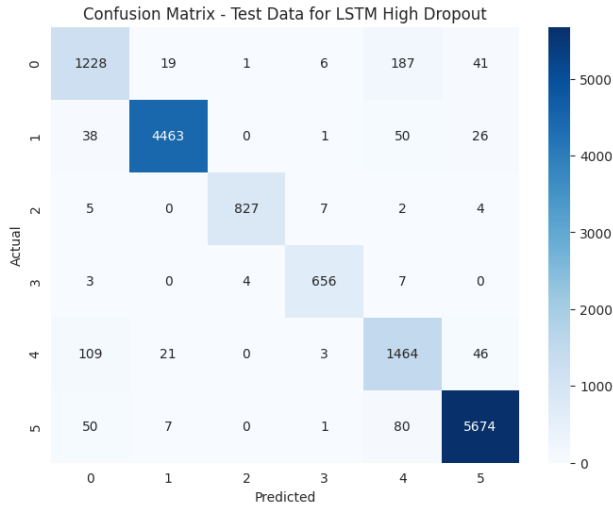
$$Precision = \frac{TP}{TP+FP} \quad (3)$$

د. المتوسط الحسابي ($macro avg$):

المتوسط الحسابي يستخدم لحساب متوسط قيم المعايير الأدائية (مثل الدقة والاستدعاء وقيمة F1 score) عبر كل الفئات بدون اعتبار لحجم الفئات. باستخدام المعادلة [6]:

$$Macro Avg = \frac{\sum_{i=1}^n Metric_i}{Total support} \quad (4)$$

هـ. المتوسط المرجح ($weighted avg$):



الشكل 14: مصفوفة الارتباك لبيانات الاختبار لنموذج LSTM اعلى.

بيانات التحقق: تم الحصول علي نتائج بيانات التحقق وفق الشكل 15

Accuracy: 0.945309381237525

Classification Report:

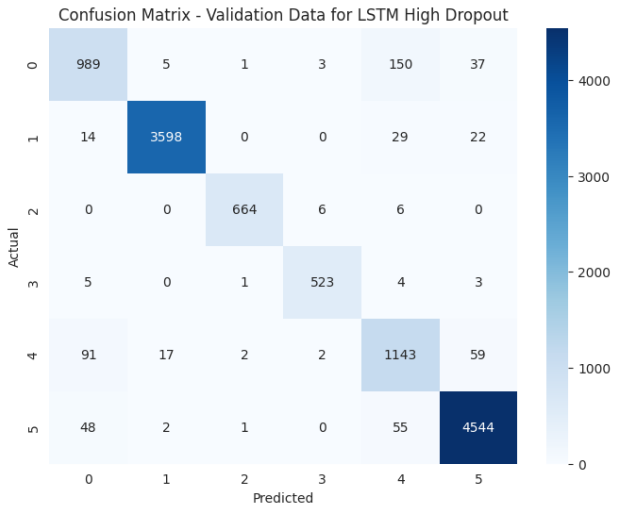
	precision	recall	f1-score	support
0	0.88	0.79	0.83	1482
1	0.99	0.97	0.98	4578
2	0.99	0.98	0.99	845
3	0.98	0.98	0.98	670
4	0.78	0.86	0.82	1643
5	0.96	0.98	0.97	5812

accuracy			0.95	15030
macro avg	0.93	0.93	0.93	15030
weighted avg	0.95	0.95	0.95	15030

كتالي:

الشكل 15: نتائج بيانات التحقق لنموذج LSTM مع نسبة Dropout اعلى.

أعطت مصفوفة الارتباك Confusion Matrix لبيانات التحقق للنموذج وفق الشكل 16 كتالي:



الشكل 16: مصفوفة الارتباك لبيانات التحقق لنموذج LSTM اعلى.

ج. نموذج LSTM مع نسبة Dropout اقل

بيانات الاختبار: تم الحصول علي نتائج بيانات الاختبار وفق الشكل 17 كتالي:

بيانات التحقق: تم الحصول علي نتائج بيانات التحقق وفق الشكل 11

Accuracy: 0.9508196721311475

Classification Report:


	precision	recall	f1-score	support
0	0.87	0.82	0.85	3175
1	0.97	0.98	0.98	9811
2	0.99	0.97	0.98	1811
3	0.99	0.98	0.99	1435
4	0.86	0.81	0.84	3520
5	0.97	0.99	0.98	12456

accuracy			0.95	32208
macro avg	0.94	0.93	0.93	32208
weighted avg	0.95	0.95	0.95	32208

كتالي:

الشكل 11: نتائج بيانات التدريب نموذج CNN.

أعطت مصفوفة الارتباك Confusion Matrix لبيانات التحقق للنموذج وفق الشكل 12 كتالي:



الشكل 12: مصفوفة الارتباك لبيانات التحقق لنموذج CNN.

ب. نموذج LSTM مع نسبة Dropout اعلى

بيانات الاختبار: تم الحصول علي نتائج الاختبار وفق الشكل 13 كتالي:

Accuracy: 0.9508196721311475

Classification Report:

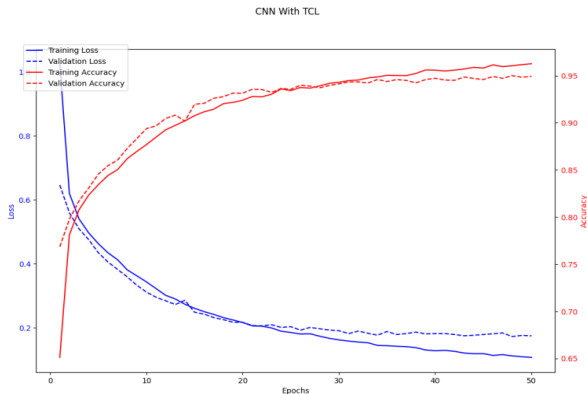
	precision	recall	f1-score	support
0	0.87	0.82	0.85	3175
1	0.97	0.98	0.98	9811
2	0.99	0.97	0.98	1811
3	0.99	0.98	0.99	1435
4	0.86	0.81	0.84	3520
5	0.97	0.99	0.98	12456

accuracy			0.95	32208
macro avg	0.94	0.93	0.93	32208
weighted avg	0.95	0.95	0.95	32208

الشكل 13: نتائج بيانات الاختبار نموذج LSTM مع نسبة Dropout اعلى.

أعطت مصفوفة الارتباك Confusion Matrix لبيانات الاختبار للنموذج وفق الشكل 14 كتالي:

حقق نموذج CNN مع طبقة TCL في الحقبة الأولى من عملية التدريب، والتي تمثل بداية التعلم للنموذج، حصلنا على قيمة الخسارة (loss) تقدر بـ 1.0252 ونسبة الدقة (accuracy) تقدر بـ 0.6511 على بيانات التدريب. هذا يعني أن النموذج كان يُصنف بشكل صحيح حوالي 65.11% من النماذج في مجموعة البيانات التدريب. بالنسبة لبيانات التحقق، كانت قيمة الخسارة (val_loss) تقدر بـ 0.6460 ونسبة الدقة (val_accuracy) تقدر بـ 0.7685. هذا يعني أن النموذج كان يصنف بشكل صحيح حوالي 76.85% من النماذج في مجموعة بيانات التحقق. في الحقبة الأخيرة من عملية التدريب، والتي تمثل النهاية المتقدمة من عملية التعلم، حصلنا على قيمة الخسارة (loss) تقدر بـ 0.1071 ونسبة الدقة (accuracy) تقدر بـ 0.9627 على بيانات التدريب. هذا يعني أن النموذج أصبح يُصنف بشكل صحيح حوالي 96.27% من النماذج في مجموعة البيانات التدريب. بالنسبة لبيانات التحقق في الحقبة الأخيرة، كانت قيمة الخسارة (val_loss) تقدر بـ 0.1745 ونسبة الدقة (val_accuracy) تقدر بـ 0.9493. هذا يعني أن النموذج كان يُصنف بشكل صحيح حوالي 94.93% من النماذج في مجموعة البيانات التحقق. النتائج في الشكل 21 تشير إلى تحسن كبير في أداء النموذج خلال عملية التدريب، حيث انخفضت قيمة الخسارة وزادت نسبة الدقة للبيانات التدريب وبيانات التحقق على حد سواء. يُعتبر هذا تطوراً إيجابياً يشير إلى أن النموذج يتعلم بشكل جيد ويصبح أكثر دقة مع تقدم عملية التدريب.



الشكل 21: دالة الخسارة ونسبة الدقة في نموذج CNN.

حقق نموذج LSTM مع نسبة Dropout أعلى في الحقبة الأولى من عملية التدريب، والتي تمثل بداية التعلم للنموذج، حصلنا على قيمة الخسارة (loss) تقدر بـ 1.0607 ونسبة الدقة (accuracy) تقدر بـ 0.6102 على بيانات التدريب. هذا يعني أن النموذج كان يُصنف بشكل صحيح حوالي 61.02% في مجموعة بيانات التدريب. بالنسبة لبيانات التحقق، كانت قيمة الخسارة (val_loss) تقدر بـ 0.6227 ونسبة الدقة (val_accuracy) تقدر بـ 0.7883. هذا يعني أن النموذج كان يصنف بشكل صحيح حوالي 78.83% من النماذج في مجموعة البيانات التحقق. في الحقبة الأخيرة من عملية التدريب، والتي تمثل النهاية المتقدمة من عملية التعلم، حصلنا على قيمة الخسارة (loss) تقدر بـ 0.1012 ونسبة الدقة (accuracy) تقدر بـ 0.9684 على بيانات التدريب. هذا يعني أن النموذج أصبح يُصنف بشكل صحيح حوالي 96.84% في مجموعة بيانات التدريب. بالنسبة لبيانات التحقق في الحقبة الأخيرة، كانت قيمة الخسارة (val_loss) تقدر بـ 0.1793 ونسبة الدقة (val_accuracy) تقدر بـ 0.9456. هذا يعني أن النموذج كان يُصنف بشكل صحيح حوالي 94.56% في مجموعة بيانات التحقق. النتائج كما في الشكل 22 تشير إلى تحسن كبير في أداء النموذج خلال عملية التدريب، حيث انخفضت قيمة الخسارة وزادت نسبة الدقة لبيانات التدريب وبيانات التحقق على حد سواء. يُعتبر هذا تطوراً إيجابياً يشير إلى أن النموذج يتعلم بشكل جيد ويصبح أكثر دقة مع تقدم عملية التدريب.


Accuracy: 0.945309381237525

Classification Report:

	precision	recall	f1-score	support
0	0.88	0.79	0.83	1482
1	0.99	0.97	0.98	4578
2	0.99	0.98	0.99	845
3	0.98	0.98	0.98	670
4	0.78	0.86	0.82	1643
5	0.96	0.98	0.97	5812
accuracy			0.95	15030
macro avg	0.93	0.93	0.93	15030
weighted avg	0.95	0.95	0.95	15030

الشكل 17: نتائج بيانات الاختبار لنموذج LSTM مع نسبة Dropout أقل.

أعطت مصفوفة الارتباك Confusion Matrix لبيانات الاختبار للنموذج وفق الشكل 18 كالتالي:



الشكل 18: مصفوفة الارتباك لبيانات التدريب لنموذج LSTM أقل.

بيانات التحقق: تم الحصول على نتائج بيانات التحقق وفق الشكل 19 كالتالي:


Accuracy: 0.9530861897665176

Classification Report:


	precision	recall	f1-score	support
0	0.87	0.83	0.85	3175
1	0.99	0.97	0.98	9811
2	0.98	0.98	0.98	1811
3	0.97	0.99	0.98	1435
4	0.84	0.87	0.86	3520
5	0.97	0.98	0.98	12456
accuracy			0.95	32208
macro avg	0.94	0.94	0.94	32208
weighted avg	0.95	0.95	0.95	32208

الشكل 19: نتائج بيانات التحقق لنموذج LSTM مع نسبة Dropout أقل.

أعطت مصفوفة الارتباك Confusion Matrix لبيانات التحقق للنموذج وفق الشكل 20 كالتالي:



الشكل 20: مصفوفة الارتباك لبيانات التحقق لنموذج LSTM أقل.



الشكل 24: دالة الخسارة ونسبة الدقة للنماذج المستخدمة في الدراسة.

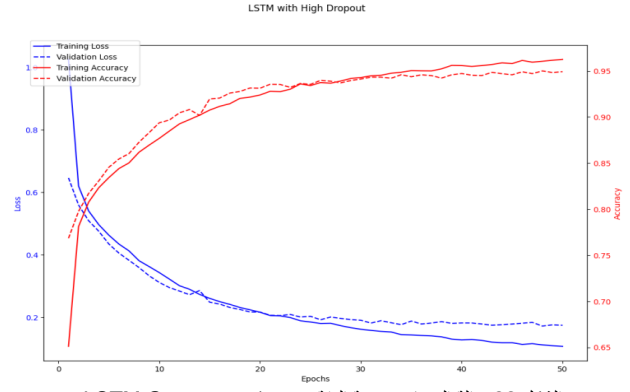
8. الخاتمة والتوصيات

بناءً على النتائج المقدمة، يمكن التأكيد على تحقيق نتائج مشجعة وملموسة من قبل النماذج الثلاثة المختلفة المستخدمة في هذه الدراسة. فقد تم التدريب والتحقق من نموذج CNN مع طبقة TCL ونموذج LSTM مع نسبة Dropout أعلى وأخرى أقل، وقد أظهرت جميعها أداءً متميزاً على مجموعة بيانات WISDM للأنشطة البشرية. تمتلك النتائج الثلاثة تقارباً ملحوظاً في أدائها، مما يشير إلى فعالية النماذج المستخدمة في هذا السياق. وتُظهر النتائج المتصلة عليها من التصنيف والدقة لكل نموذج أنها تفوقت على المعايير المعتادة للأداء الجيد، مما يُظهر جودة النماذج وقوتها في التعامل مع مجموعة البيانات. إضافة إلى ذلك، فإن استخدام مجموعة بيانات التحقق يُظهر استقراراً وقوة النماذج المدربة، حيث أن النتائج على مجموعة البيانات للتحقق تعكس قدرة النماذج على التعميم على بيانات جديدة وغير مرئية. بناءً على هذه النتائج الواعدة، يمكن الاعتماد على هذه النماذج في تطبيقات الكشف عن الأنشطة البشرية بشكل عام، وخاصة في السياقات التي تتطلب دقة واستقراراً مرتفعاً في التصنيف. ومع الأخذ في الاعتبار أن النتائج التي تم الحصول عليها تمثل تطبيقاً لنماذج معينة على مجموعة بيانات محددة، يمكن استكشاف وتطوير استخدامات أوسع لهذه النماذج في البحوث المستقبلية والتطبيقات العملية. من خلال النتائج التي توصلت لها الدراسة يمكن أن تكون التوصيات كالتالي:

1. تخصيص معاملات متخصصة لكل نموذج لتحسين جودة النتائج.
2. ننصح باعتماد التقسيم المتقاطع بدلاً من التقسيم التقليدي المستخدم في الدراسة.
3. نوصي بالحصول على بيانات من مصادر أخرى في البيئة المحلية، مثل أجهزة الهواتف الذكية، لتحقيق التأكيد على جودة النماذج.

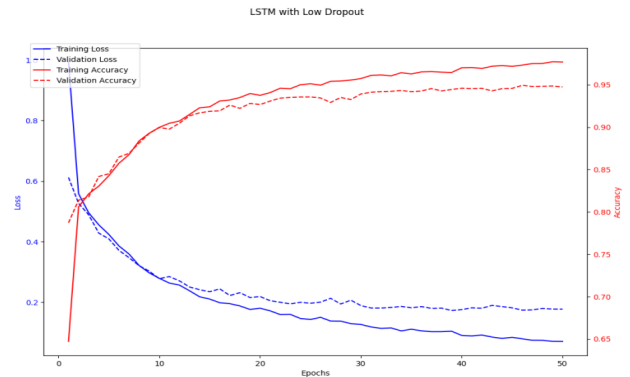
9. الأعمال المستقبلية

1. استكشاف تعديل معاملات النماذج الثلاثة بشكل متخصص، مثل تعديل مستويات التسريب (Dropout) أو تعديل عدد الطبقات وأحجامها، بهدف تحسين جودة النتائج وزيادة دقتها.
2. توسيع دراسات التقسيم المتقاطع لتحديد فعالية هذه الطريقة مقارنة بالتقسيم التقليدي، وتحليل تأثيرها على استقرارية وأداء النماذج المستخدمة.
3. جمع بيانات إضافية من مصادر متنوعة في البيئة المحلية، مثل أجهزة الهواتف الذكية، وتضمينها في عمليات التدريب والتحقق لتعزيز تنوع وشمولية مجموعة البيانات وبالتالي تحسين أداء النماذج.
4. استكشاف تقنيات التعميم العميق لزيادة قدرة النماذج على التعامل مع بيانات جديدة ومختلفة عن تلك المستخدمة في التدريب، مما قد يساهم في تعزيز قابلية استخدام النماذج في سياقات العمل الفعلية.



الشكل 22: دالة الخسارة ونسبة الدقة في نموذج LSTM Generous.

حقق نموذج LSTM مع نسبة Dropout أقل في الحقبة الأولى من عملية التدريب، حصلنا على قيمة الخسارة (loss) التي تقدر بـ 0.9936 ونسبة الدقة (accuracy) التي تقدر بـ 0.6470 على بيانات التدريب. يُعتبر هذا أداءً مقبولاً للنموذج في بداية التدريب، حيث يتم تصنيف حوالي 64.70% بشكل صحيح في مجموعة البيانات التدريب. بالنسبة لبيانات التحقق، كانت قيمة الخسارة (val_loss) تقدر بـ 0.6118 ونسبة الدقة (val_accuracy) تقدر بـ 0.7871. هذا يعني أن النموذج كان يصنف بشكل صحيح حوالي 78.71% من النماذج في مجموعة البيانات التحقق. أما في الحقبة الأخيرة من عملية التدريب، والتي تمثل النهاية المتقدمة من عملية التعلم، حصلنا على قيمة الخسارة (loss) التي تقدر بـ 0.0706 ونسبة الدقة (accuracy) التي تقدر بـ 0.9768 على بيانات التدريب. هذا يعني أن النموذج أصبح يصنف بشكل صحيح حوالي 97.68% من النماذج في مجموعة البيانات التدريب. بالنسبة لبيانات التحقق في الحقبة الأخيرة، كانت قيمة الخسارة (val_loss) تقدر بـ 0.1772 ونسبة الدقة (val_accuracy) تقدر بـ 0.9474. هذا يعني أن النموذج كان يصنف بشكل صحيح حوالي 94.74% من النماذج في مجموعة البيانات التحقق. النتائج كما في الشكل 23 تشير إلى تحسن كبير في أداء النموذج خلال عملية التدريب، حيث انخفضت قيمة الخسارة وزادت نسبة الدقة للبيانات التدريب وبيانات التحقق على حد سواء. يُعتبر هذا تطوراً إيجابياً يشير إلى أن النموذج يتعلم بشكل جيد ويصبح أكثر دقة مع تقدم عملية التدريب.



الشكل 23: دالة الخسارة ونسبة الدقة في نموذج LSTM Conservative.

من خلال مقارنة النماذج المستخدمة في الدراسة كما الشكل 24 من حيث الدقة وقيمة الخسارة خلال التدريب والتحقق تبين أن النماذج متقاربة جداً في التنبؤ بالنشاط البشري.

5. توجيه الجهود نحو تطبيق النماذج في مجالات عملية محددة، مثل تطبيقات الرصد الصحي أو التنبؤ بالسلوك البشري، لاختبار فعالية النماذج في سياقات استخدام حقيقية.

المراجع

- [1] L. Alawneh, B. Mohsen, M. Al-Zinati, A. Shatnawi and M. Al-Ayyoub, "A Comparison of Unidirectional and Bidirectional LSTM Networks for Human Activity Recognition," 2020 IEEE International Conference on Pervasive Computing and Communications Workshops (PerCom Workshops), Austin, TX, USA, 2020, pp. 1-6, doi: 10.1109/PerComWorkshops48775.2020.9156264.
- [2] Yin, X., Liu, Z., Liu, D., & Ren, X. (May 2022). A Novel CNN-based Bi-LSTM parallel model with attention mechanism for human activity recognition with noisy data. *Scientific Reports*, 12(1). <https://doi.org/10.1038/s41598-022-11880-8>.
- [3] Zebin, T., Sperrin, M., Peek, N., & Casson, A. J. (2018). Human activity recognition from inertial sensor time-series using batch normalized deep LSTM recurrent networks. In *Annu Int Conf IEEE Eng Med Biol Soc*, (pp. 1-4). doi: 10.1109/EMBC.2018.8513115.
- [4] Palla, S. R. (2020). Human activity recognition using machine learning and deep learning models. Medium. Retrieved December 30, 2023, from <https://sanjeev-palla.medium.com/human-activity-recognition-using-machine-learning-and-deep-learning-models-e56b35f02161>.
- [5] Grus, J. (2019). *Data Science from Scratch: First Principles with Python* (2nd ed.). O'Reilly Media.
- [6] N. Ashraf, W. Ahmad, and R. Ashraf, "A Comparative Study of Data Mining Algorithms for High Detection Rate in Intrusion Detection System," *Annals of Emerging Technologies in Computing (AETiC)*, vol. 2, no. 1.