

تصميم نظام لكشف السقوط المؤذي للإنسان بكاميرات المراقبة

Designing A System for Detecting the Harmful Fall of Human Based on Surveillance Cameras

م. عمار محمد ياسر الدقاق

المشرف المشارك: د.م. رشا مسعود

المشرف الرئيسي: د. م. محمد مازن المحاييري

القسم العملي

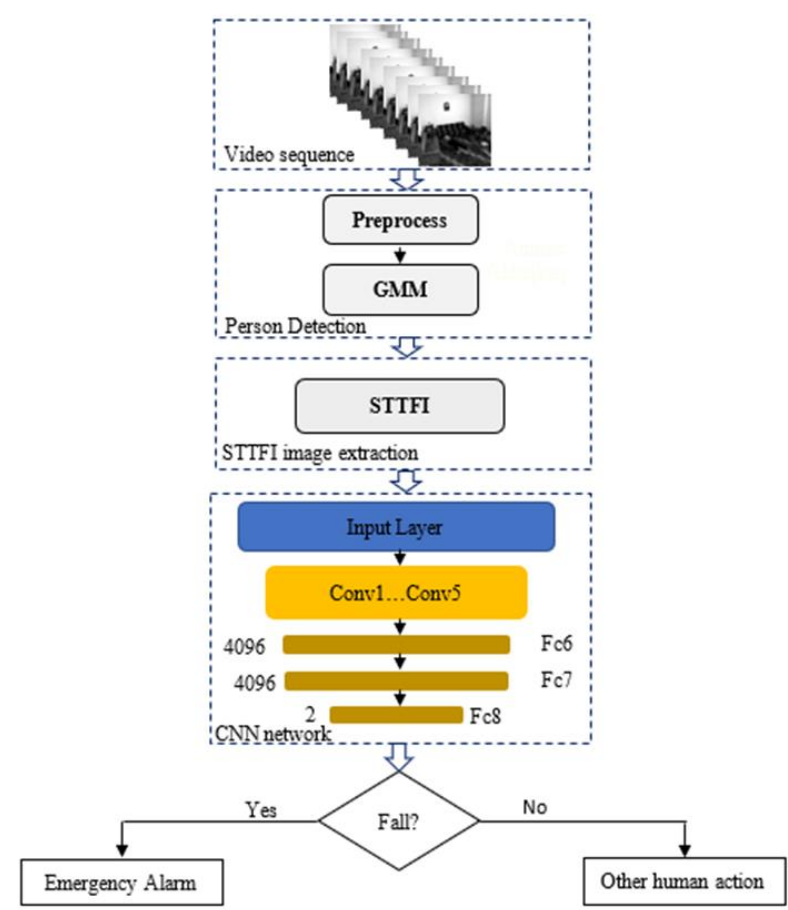
المنظومة المقترحة الثانية: تم فيها اقتراح صورة جديدة STTFI تعطي بالمعادلة:

$$STTFI(x, y, t) = \begin{cases} STTFI(x, y, t-1) + KT + 1 & \text{if } f(x, y, t) = 1 \\ STTFI(x, y, t-1) & \text{otherwise} \end{cases}$$

تعبّر عن عدة إطارات من الفيديو حيث يمثل فيها الوضعيات المرحلية التي يمر فيها الجسم أثناء السقوط مع الأزمنة التي حدثت عندها إضافة إلى اتجاه الحركة، وذلك خلافاً لصور MHI التي تمثل كمية الحركة واتجاهها فقط، كما تعاني من التغطية الذاتية التي تلافتها الطريقة المقترحة.

كما صورت مجموعة تدريب جديدة FD22 تحوي وضعيات سقوط لم تكن موجودة في المجموعات السابقة مثل السقوط نتيجة الإغماء والسقوط من على الأريكة.

استخدمت في التدريب المجموعات (FDD, URFD, Umontreal, FD22)

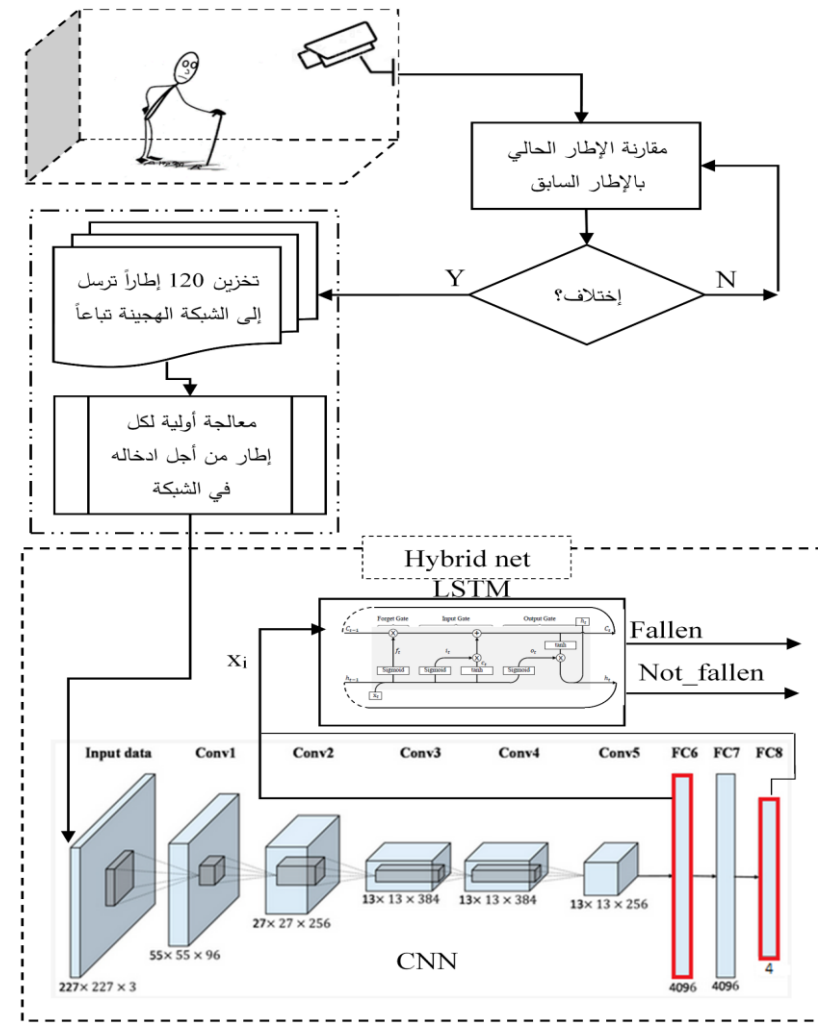


القسم العملي

المنظومة الأولى المقترحة:

استخدمت فيها شبكة هجينة Alexnet-LSTM، حيث اقترحت أربعة وضعيات مرحلية جديدة لتميزها Alexnet ودربت عليها، ثم دربت LSTM على شعاع جديد مأخوذ من الطبقتين الأخيرتين F8 والطبقة F6 بحيث يمثلان سمات عمومية وتفصيلية تميز كل مرحلة من المراحل الأربعة المقترحة (الزلزل، التساقط، السقوط، آخر).

استخدمت مجموعات التدريب التالية: (FDD, UFD, Umontreal)



الملخص

ساهم انتشار تقنيات الذكاء الصناعي في العقد الأخير، ورخص الكاميرات وانتشارها الواسع، في الاهتمام بتصنيف حركات وأفعال البشر خاصة تلك الأفعال التي قد يكون لها أثر سلبي في صحتهم، وقد يؤدي في أسوأ الأحوال إلى وفاتهم، وكان لحدث السقوط الحظ الأكبر من الدراسات والبحوث، وخاصة فيما يتعلق ب كبار السن، فغالباً خطر الموت نتيجة السقوط يكون من نصيبهم. لذلك تم في هذا البحث طرح منظومتين جديدتين لكشف السقوط المؤذي.

المنظومة الأولى تعتمد على شبكة هجينة CNN-LSTM يتم فيها الربط بين الشبكتين LSTM و CNN بشعاع سمات جديد يحمل سمات عمومية وتفصيلية، ويعرف وضعيات مرحلية ثلاثة متتالية متعاقبة تعرف أنواع السقوط المختلفة، ووضعية "آخر" لبقية الأحداث المخالفة للسقوط.

المنظومة الثانية تعتمد على شبكة التفاضلية CNN وتستخدم صورة جديدة تمثل الحركة والوضعيات المرحلية الساكنة التي تمر بها أجزاء الجسم مرتبطة بأزمته حدوثها، وقد دعيت تلك الطريقة صورة أمامية مكدسة بعلامات زمنية Stacked Time-Tagged Foreground Image (STTFI).

ونوقشت بعد اقتراح كل من المنظومتين دقة كل منهما، كما قورنتا بالأنظمة الأخرى التي تقوم بكشف السقوط، حيث أعطت المنظومتان دقة وحساسية أفضل من أغلب المنظومات المقترحة سابقاً.

النتائج والمناقشة

تفوقت الطريقة الأولى المقترحة على الطرق التي استخدمت شبكة هجينة CNN-LSTM وقد أعطت هذه الطريقة دقة 98.6%، تغلبت الطريقة المقترحة هذه على كلين في الشبكات الهجينة، الأول هو معرفة الرابط الزمني بين مثلاً الانحناء والاستلقاء، أما الثاني فهو استخدام سمات عمومية لمعرفة النشاط فسقوط عن سقوط يفرق.

استطاعت صور STTFI المقترحة الثانية تمثل الوضعيات المرحلية الساكنة التي يمر بها الجسم البشري أثناء السقوط، كما تلافت سيئة التغطية الذاتية وقصور الطرق السابقة مثل MHI في تمثيل الحركة عندما يكون محور الحركة موازياً لمحور الرؤية. وقد أعطت هذه الطريقة عند استخدامها مع شبكة Alexnet نتائج تفوقت على بقية الطرق التي استخدمت صور MHI لكشف السقوط، حيث بلغت دقتها 99.02%.

يوصى باتباع أجد النهجين عند اكتشاف نشاط معين قد يقوم به الإنسان خاصة تلك الأنشطة غير الطبيعية التي تحصل للإنسان مثل السقوط كخالة دراسية في هذا البحث.

القسم النظري

ظهرت العديد من الدراسات في العقد الأخير لتطوير أنظمة ذكية يمكنها اكتشاف حدوث السقوط [1]، وكان الحظ الأوفر لتقنيات التعلم العميق.

فهناك [2] من اعتمد على صور ملتقطة لأشخاص مستقلقين على الأرض بلحظات زمنية معينة واعتمدها كدخل لشبكة عميق لتحديد حدث السقوط، مغفلاً بذلك الوضعيات المرحلية التي تسبق السقوط والأزمته التي حدثت فيها، أو استخدام صور تمثل [3] عدة إطارات بسمات زمنية حركية مع إهمال الوضعيات المرحلية.

وهناك [4] من اعتمد على التتابع الزمني لمجموعة سمات حركية مستخلصة من الصور المنتقاة من الفيديو لتحديد حدث السقوط، وقد أهمل الوضعيات المرحلية الساكنة التي يأخذها الجسم أثناء السقوط.

إن الوضعيات المرحلية التي يأخذها الجسم أثناء السقوط تعطي سمات مهمة تميز السقوط عن الحالات المماثلة التي قد تفسر خطأ على أنها سقوط.

المراجع

[1] J. Gutiérrez, V. Rodríguez and S. Martin, "Comprehensive Review of Vision-Based Fall Detection Systems," *Sensors*, 21(3), pp. 1-50, 2021.

[2] T. CHEN, Z. DING and B. LI, "Elderly Fall Detection Based on Improved YOLOv5s Network," *IEEE Access*, pp. 91273-91282, 2022.

[3] C. Khraief, F. Benzarti and H. Amiri, "Elderly fall detection based on multi-stream deep convolutional networks," *Multimedia Tools and Applications*, p. 19537-19560, 25 3 2020.

[4] D. Sangwan, R. Manekar, S. Saurav, S. Maiti, S. Singh, S. Chaudhury, N. Kumar, R. Kumar and K. Chaudhary, "Activity Recognition for Indoor Fall Detection in 360-Degree Videos Using Deep Learning Techniques," in *3rd International Conference on Computer Vision and Image Processing*, New delhi, India, 2020.