

## التنبؤ بالسلوك لشخص مسن يعيش في منزل ذكي باستخدام المتوسط المتحرك المرجح الآسي ونظام الاستدلال الضبابي الشبكي

أيمن السنوسي أبو فناس

قسم علوم الحاسوب - المعهد العالي للعلوم والتقنية مصراتة - ليبيا

[Ayman.abufanas@gmail.com](mailto:Ayman.abufanas@gmail.com)

أبو بكر محمد البيوضي

قسم علوم الحاسوب - كلية تقنية المعلومات - جامعة  
مصراتة - ليبيا

[abubakerelbayoudi@it.misuratau.edu.ly](mailto:abubakerelbayoudi@it.misuratau.edu.ly)

### المخلص

تهدف المنازل الذكية إلى تعزيز وتسهيل الحياة اليومية للأفراد وخاصة كبار السن منهم، وكذلك الأشخاص الذين يعانون من بعض الأمراض التي تعيق الحركة أو التفكير. إن هؤلاء الأشخاص سيستفيدون من التطور التقني في هذا المجال فهم الذين يتوقون إلى العيش بمفردهم في منازلهم واختياراتهم لترتيب معيشتهم بما يتناسب مع رغباتهم، مع توفير الرعاية الصحية التي يحتاجون إليها من خلال مراقبة حركتهم اليومية من قبل ذويهم أو المكلفين بمتابعتهم.

ففي هذا البحث تمت دراسة بيانات حقيقية متاحة من جامعة واشنطن دي سي، والتي تم تسجيلها للسلوك اليومي لعدد من كبار السن الذين يسكنون في منازل ذكية مجهزة بشبكة من المستشعرات قادرة على تسجيل الحركة اليومية لكل منهم. وذلك من أجل تسجيل بيانات أنماط السلوك والنشاط اليومي لكل منهم، وبناء على هذه البيانات فإنه يتم تحليل ونمذجة السلوك اليومي للشخص المعني وذلك لتحديد أنماط السلوك الطبيعي واكتشاف السلوك غير الطبيعي (العارض) والذي قد يكون مؤشرا على حدوث عرض طارئ لهذا الشخص مثل السقوط أو المرض. لقد تم في هذا البحث استخدام المتوسط المرجح المتحرك الآسي Exponential Moving Weighted Average (EMWA) ونظام الاستدلال الضبابي الشبكي Adaptive Neuro-Fuzzy Inference System (ANFIS) لتحليل البيانات وذلك من أجل تحديد أنماط السلوك اليومي وكذلك اكتشاف السلوك غير الطبيعي إن وجد. وبعد ذلك يتم استخدام هاتين التقنيتين للتنبؤ ببيانات السلوك القادم من خلال مقارنته بالبيانات المسجلة مسبقا عن سلوك نفس الشخص. إن نتائج البحث أظهرت قدرة الطرق المستخدمة فيه على التنبؤ بالسلوك اليومي وكذلك اكتشاف التغيرات في السلوك اليومي للمعني.

استلمت الورقة بتاريخ  
2025/07/27، وقبلت  
بتاريخ  
2025/08/10  
ونشرت  
بتاريخ  
2025/08/11

### الكلمات المفتاحية:

التنبؤ بالسلوك البشري -  
ANFIS - EMWA  
ADL

## 1. المقدمة

التدهور التدريجي في الصحة الجسدية والعقلية يمنع كبار السن من العيش بشكل مستقل ومن أداء أنشطة الحياة اليومية (ADL (activities of daily living). مع زيادة كبيرة في عدد السكان المسنين، فإن أحد الحلول التي تساعد في حل بعض المشكلات ذات الصلة هو تقنيات البيئة الذكية، ومراقبة الأشخاص في بيئاتهم الذكية أثناء قيامهم بأنشطتهم. قد يساعد استنباط أسلوب حياتهم وتوقع احتياجاتهم على التغييرات في صحة الشخص والتفكير في الأنشطة في الحياة اليومية. جمع الأنماط المتكررة في عدد المرات للقيام بعمل ما وحساب الوقت في كل مرة لهذا السبب، أصبح من الضرورة جمع البيانات التي تمثل الأنشطة اليومية (ADL) بشكل كامل ودقيق. يتضمن ذلك توقيت النوم، وعدد ساعات النوم اليومية، وكذلك عدد مرات دخول الحمام والوقت المستغرق في كل زيارة. من خلال مراقبة أنماط سلوك المستخدمين على مدار فترة طويلة، يمكننا تحليل هذه البيانات والكشف عن أي تشوهات أو اضطرابات في الأنشطة اليومية. وبالتالي، يجب استخدام تقنيات جمع البيانات في بيئات المنزل الذكي بشكل فعال لضمان استمرارية وجود البيانات المجمع. واكتسبت التكنولوجيا الذكية المستخدمة في البيئات الذكية القدرة على دعم حياة كبار السن وتحسين جودة حياتهم اليومية. من بين التحديات التي تواجهها هو التنبؤ بسلوك كبار السن في هذه البيئات الذكية لتوفير الرعاية الملائمة والدعم اللازم.

إن التعرف على السلوك البشري هو عملية تحديد وتفسير أنماط السلوك البشري من البيانات، مثل تسجيلات الفيديو أو الصوت. يمكن القيام بذلك من خلال استخدام تقنيات مختلفة، مثل الذكاء الاصطناعي وخوارزميات التعلم الآلي. غالبًا ما يكون الهدف من التعرف على السلوك البشري هو فهم والتنبؤ بكيفية تصرف الناس في مواقف معينة، أو تحديد السلوك غير العادي أو غير الطبيعي. يتم استخدام التعرف على السلوك البشري في مجموعة متنوعة من الإعدادات، بما في ذلك أبحاث علم النفس والأمن والمراقبة والتسويق وخدمة العملاء. من المهم ملاحظة أن التعرف على السلوك البشري يمكن أن يثير مخاوف أخلاقية، مثل احتمال انتهاك الخصوصية أو التمييز.

في هذا البحث، نقدم دراسة شاملة للتنبؤ بالسلوك اليومي لكبار السن في بيئة ذكية ونقوم بمقارنة بين نموذجين رئيسيين: نموذج (ANFIS (Adaptive Neuro-Fuzzy Inference System) ونموذج EMWA (Exponential Moving Weighted Average). تستند هذه الدراسة إلى بيانات حقيقية يومية مقدمة من موقع مركز الدراسات المتقدمة في الأنظمة التكيفية (casas) وهو موقع تعليمي متخصص في توفير فواعد بيانات في مجال المنازل الذكية، تم استخدام بيانات الأنشطة اليومية لأحد كبار السن مقيم في منزل ذكي لمدة شهر واحد وهي عبارة عن سجل يومي لمراقبة نومة خلال مدة 28 يومًا، تم تحليل هذه البيانات لاستخراج الأنماط غير المعتادة في سلوك هذا المسن لتمييز حالته الصحية من خلال تحليل سجل نومة للمدة المذكورة، يهدف النموذج ANFIS إلى استخدام شبكات عصبية اصطناعية ومنطق ضبابي للتنبؤ بالسلوك اليومي، في حين يعتمد النموذج EMWA على حساب المتوسط المتحرك الأساسي للبيانات السابقة والقيام بنفس المهمة. سيتم تدريب وتقييم النموذجين باستخدام البيانات المجمع والمعالجة. تهدف هذه الدراسة إلى تحسين فهمنا للسلوك اليومي لكبار السن في بيئة ذكية، وتوفير أدوات وتقنيات للتنبؤ المبكر بالاحتياجات الصحية والرعاية اللازمة. من خلال المقارنة بين نموذجي ANFIS وEMWA، سنقيم كفاءة كل نموذج في التنبؤ وقدرته على التكيف مع تغيرات السلوك اليومي. نأمل أن تسهم نتائج هذه الدراسة في تعزيز جودة الرعاية والدعم المقدم لكبار السن في بيئاتنا الذكية، وتوفير توجيهات للبحوث والتطبيقات المستقبلية في هذا المجال.

إن الهدف الرئيسي لهذا البحث هو استكشاف ودراسة التنبؤ بالسلوك اليومي لفئة كبار السن الذين يعيشون في بيئة ذكية. وذلك من خلال تحديد وفهم الأنماط والعوامل المؤثرة في سلوك هؤلاء الأفراد، ويتم ذلك بتحقيق الأهداف الفرعية التالية:

- التنبؤ الدقيق للسلوك اليومي لكبار السن الذين يعيشون في بيئة ذكية، وذلك بتحليل البيانات التي يتم جمعها من أجهزة الاستشعار والمراقبة، والتي يتم من خلالها استنباط معلومات حول الأنشطة والسلوك اليومي لهؤلاء الأفراد. ستتضمن العملية تجهيز هذه البيانات وتطبيق تقنيات التحليل والتعلم الآلي لاستخلاص الأنماط المهمة والمرتبطة بالسلوك اليومي مثل ANFIS EWMA.
- استكشاف وتحليل العوامل المؤثرة في سلوك كبار السن في بيئة ذكية. سيتم دراسة العوامل المتعلقة بالبيئة المحيطة بهم، العوامل الشخصية مثل الصحة والمزاج والنشاط البدني من خلال تحليل بيانات نومهم. ستساهم هذه الدراسة في فهم أفضل للعوامل التي تؤثر على سلوك كبار السن وتسهم في عملية التنبؤ.
- تحسين الرعاية والدعم المقدم لكبار السن الذين يعيشون في بيئة ذكية. ستستند هذه الجوانب على قدرة التنبؤ بالسلوك اليومي لهؤلاء الأفراد لتوفير الدعم والرعاية الملائمة. يمكن استخدام نتائج البحث لتوفير توجيهات ونصائح لكبار السن للمساعدة في إدارة نشاطاتهم اليومية بشكل أفضل وتلبية احتياجاتهم الفردية.

- استخدام النتائج والتوصيات لتطوير تطبيقات وأنظمة ذكية تستهدف كبار السن في حياتهم اليومية. بناءً على النتائج المحققة، يمكن تطوير تطبيقات مبتكرة توفر دعماً مستمراً لكبار السن. يمكن لهذه التطبيقات تذكيرهم بالأنشطة المهمة، وتقديم نصائح صحية، وتنظيم جدول أعمالهم، وتوفير وسائل اتصال لطلب المساعدة عند الحاجة.

ستكون هيكلية البحث وفقاً للقرارات الرئيسية التالية: الدراسات السابقة، منهجية البحث، النتائج وأخيراً الخلاصة والتوصيات.

## 2. الدراسات السابقة

دراسة أنشطة الحياة اليومية (Activities of Daily Living - ADLs) هي عبارة عن تقييم وتحليل للقدرة الشخصية على أداء الأنشطة الأساسية التي يحتاجها الفرد للحياة اليومية والاعتماد الذاتي. تتعلق هذه الأنشطة بالحياة اليومية الروتينية وتشمل القدرة على الاستحمام والنظافة الشخصية، والأكل والشرب، واللباس، واستخدام التواليت، والتنقل والحركة، والاستخدام المنزلي تهدف دراسة أنشطة الحياة اليومية إلى تقييم مدى القدرة الشخصية على الاستقلالية والتحكم في حياتهم اليومية. يتم استخدام هذا التقييم في مجالات عديدة مثل التشخيص الطبي، والعلاج الطبيعي، ورعاية المسنين، والإعاقة والتأهيل يتم تحليل أنشطة الحياة اليومية في إطار القدرة على القيام بالأنشطة بشكل صحيح وبدون مساعدة من الآخرين. تصنف هذه الأنشطة عادة إلى قسمين: الأنشطة الأساسية والأنشطة الصعبة. الأنشطة الأساسية تشمل الأنشطة الضرورية للحياة اليومية الأساسية مثل الاستحمام والتنظيف والتغذية، تعد دراسة أنشطة الحياة اليومية أداة هامة في تقييم تأثير الإعاقة أو الحالة الصحية على قدرة الشخص على العيش بشكل مستقل وتحديد احتياجات الرعاية والدعم المناسبة. يُستخدم هذا التقييم أيضاً في تخطيط الرعاية الشخصية وتوفير الخدمات الملائمة لتحسين جودة حياة الأفراد. [1]

ففي دراسة لتقديم مسح حول التعرف على النشاط البشري باستخدام مستشعرات يمكن ارتداؤها، قدمت هذه الدراسة نظرة عامة على التقنيات والأساليب المختلفة المستخدمة للتعرف على الأنشطة البشرية في المنازل الذكية باستخدام أجهزة استشعار يمكن ارتداؤها. يغطي المسح نهج التعلم الخاضع للإشراف وغير الخاضع للإشراف، ويناقش مزايا وقيود كل نهج. يغطي المسح أيضاً أنواعاً مختلفة من أجهزة الاستشعار التي يمكن ارتداؤها والتي تم استخدامها للتعرف على النشاط، مثل مقاييس التسارع والجيروسكوبات وأجهزة استشعار تخطيط العضل الكهربائي [1].

ففي دراسة عن التعرف على النشاط البشري في المنازل الذكية تمت دراسة التقنيات والأساليب المختلفة للتعرف على الأنشطة البشرية في المنازل الذكية. تغطي المراجعة كلاً من الأساليب المستندة إلى الأجهزة القابلة للارتداء وغير القابلة للارتداء، وتناقش مزايا وقيود كل نهج. تغطي المراجعة أيضاً أنواعاً مختلفة من المستشعرات التي تم استخدامها للتعرف على النشاط، مثل مقاييس التسارع والجيروسكوبات والكاميرات [2].

إن من أهم الأعمال البحثية التي يمكن القيام بها في هذا المجال هو الكشف عن السلوك البشري غير الطبيعي يشير إلى عملية تحديد السلوكيات غير العادية أو غير النمطية. بحيث يمكن القيام بذلك من خلال الملاحظة، والتقرير الذاتي، والتقييمات النفسية، أو باستخدام معايير التشخيص لاضطرابات الصحة العقلية. قد يكون الهدف من اكتشاف السلوك غير الطبيعي هو فهم سلوك شخص ما، أو تقديم الدعم أو العلاج، أو تحديد مشكلات الصحة العقلية المحتملة. من المهم ملاحظة أن ما يعتبر سلوكاً غير طبيعي يمكن أن يختلف اعتماداً على المعايير الثقافية والاجتماعية، وأن هذا السلوك غير الطبيعي لا يعني بالضرورة السلوك غير الصحي أو الإشكالي.

من أجل ذلك، تم اكتشاف العديد من التقنيات الإحصائية لتحليل ونمذجة الأنشطة اليومية للمقيمين في البيئات الذكية. استخدم الباحثون تقنيات إحصائية للكشف عن التغيرات أو الأنشطة غير العادية.

فمن بين النماذج المستخدمة لمتابعة النشاط البشري نموذج ماركوف المخفي Hidden Markov Model (HMM) نوعاً من النماذج الإحصائية التي يمكن استخدامها لتمثيل العلاقات الاحتمالية بين سلسلة من الملاحظات والتسلسل الأساسي للحالات التي أنتجت تلك الملاحظات. في سياق التعرف على السلوك البشري، قد تكون الملاحظات عبارة عن بيانات حسية مثل الفيديو أو التسجيلات الصوتية لأفعال الشخص، ويمكن أن تتوافق الحالات المخفية مع سلوكيات أو نوايا مختلفة. هناك العديد من الأساليب المختلفة للتدريب واستخدام HMMs للتعرف على السلوك البشري، وستعتمد التفاصيل المحددة على التطبيق المحدد والبيانات المتاحة. استخدمت إحدى الدراسات HMM للتعرف على أنشطة مثل المشي والجري وصعود السلالم في مجموعة بيانات فيديو لأفعال الإنسان. قام الباحثون بتدريب HMM باستخدام مزيج من الملصقات اليدوية واستخراج الميزات تلقائياً، وحققوا دقة عالية في مهام التعرف على النشاط. [5]

استخدمت دراسة أخرى HMM للتعرف على سلوكيات السائق مثل تغيير الحرارة والانعطافات والكبح في مجموعة بيانات محاكاة القيادة. استخدم الباحثون نظام HMM لتحديد الارتباطات بين سلوكيات السائق وإجراءات التحكم في السيارة، واستخدموا النتائج لتحسين أداء السيارة ذاتية القيادة [6]. استخدمت دراسة ثالثة HMM للتعرف على الإيماءات والحركات في مجموعة بيانات لتسلسلات فيديو لغة الإشارة. قام الباحثون بتدريب HMM على مجموعة بيانات كبيرة من فيديو لغة الإشارة المشروحة، وتمكنوا من تحقيق دقة عالية في التعرف على العلامات والجمل الفردية في مجموعة الاختبار. [7]

نموذج آخر تم استخدامه في التعرف على السلوك البشري وهو نموذج خليط غاوسيان Gaussian Mixed Model (GMM) هو مجال دراسة يتضمن استخدام تقنيات مختلفة لتحديد وفهم السلوك البشري من البيانات مثل تسجيلات الفيديو أو الصوت. إحدى التقنيات التي تم استخدامها لهذا الغرض هي نموذج الخليط الغاوسي (GMM). نموذج الخليط الغاوسي هو نموذج احتمالي يفترض أن البيانات يتم إنشاؤها من خليط من عدة توزيعات "مكونة" مختلفة، كل منها عبارة عن توزيع غاوسي. يمكن استخدام GMM لنمذجة أي توزيع للبيانات يمكن تمثيله كمزيج من عدة غاوسيين. في سياق التعرف على السلوك البشري، يمكن استخدام GMM لنمذجة توزيع الميزات المستخرجة من مقطع فيديو أو تسجيل صوتي لسلوك الشخص. على سبيل المثال، يمكن استخدام GMM لنمذجة توزيع تعابير الوجه أو وضعية الجسم أو الخصائص الصوتية للشخص المتحدث. يمكن بعد ذلك استخدام GMM لتصنيف الملاحظات الجديدة للسلوك على أنها تنتمي إلى إحدى فئات السلوك التي تم تعلمها سابقاً.

هناك العديد من الفوائد لاستخدام GMM للتعرف على السلوك البشري. تتمثل إحدى المزايا في أن GMMs قادرة على التقاط تعقيد بيانات العالم الحقيقي، والتي قد يكون لها أوضاع متعددة أو تكون موزعة بشكل غير خطي. فائدة أخرى هي أن GMMs سهلة التنفيذ نسبياً ويمكن تدريبها بكفاءة باستخدام خوارزمية تعظيم التوقع. ومع ذلك، هناك أيضاً بعض القيود على استخدام GMMs للتعرف على السلوك البشري. أحد القيود هو أن GMM تفترض أن البيانات يتم إنشاؤها من خليط من Gaussians، والذي قد لا يكون دائماً افتراضاً مناسباً. يتمثل أحد القيود الأخرى في أن GMM يمكن أن تكون حساسة للمعلمات الأولية المختارة وقد تتطلب ضبطاً دقيقاً لتحقيق أداء جيد.

ففي دراسة بحثية استخدم الباحثون GMMs للتعرف على تعبيرات الوجه في بيانات الفيديو. قاموا بتدريب GMM على مجموعة بيانات من مقاطع الفيديو لأشخاص يقومون بتعبيرات وجه مختلفة، ثم استخدموا GMM لتصنيف مقاطع فيديو جديدة لتعبيرات الوجه على أنها تنتمي إلى أحد الفصول التي تم تعلمها سابقاً [8]. في دراسة أخرى منشورة، استخدم الباحثون GMMs للتعرف على الإجراءات البشرية في بيانات الفيديو. قاموا بتدريب GMM على مجموعة بيانات من مقاطع الفيديو لأشخاص يؤدون إجراءات مختلفة، مثل المشي أو الجري أو القفز، ثم استخدموا GMM لتصنيف مقاطع فيديو جديدة للإجراءات على أنها تنتمي إلى أحد الفصول التي تم تعلمها سابقاً [9]. كما استخدم باحثون GMMs للتعرف على المشاعر البشرية من البيانات الصوتية. قاموا بتدريب GMM على مجموعة بيانات من تسجيلات الأشخاص الذين يتحدثون بمشاعر مختلفة، ثم استخدموا GMM لتصنيف التسجيلات الجديدة للكلام على أنها تعبر عن أحد المشاعر التي تم تعلمها سابقاً [10].

وفي نموذج آخر يعرف بنموذج المتوسط المتحرك تكاملي الانحدار Autoregressive Integrated Moving Average (ARIMA) والذي يمكن استخدامه لعمل تنبؤات للفرات الزمنية المستقبلية بمجرد تدريبه على البيانات التاريخية من خلال استقرار الأنماط التي تم التعرف عليها في البيانات التاريخية. ومع ذلك، من المهم ملاحظة أن دقة نموذج ARIMA تعتمد على جودة وكمية البيانات التاريخية، فضلاً عن ملاءمة معلمات النموذج. ففي دراسة عن "التنبؤ بتأثير COVID-19 على الطلب على الرعاية الصحية في النرويج باستخدام نموذج ARIMA" بواسطة A. Bråthen، وآخرون. استخدم المؤلفون نموذج ARIMA للتنبؤ بتأثير COVID-19 في الطلب على الرعاية الصحية في النرويج. تم تدريب النموذج على البيانات التاريخية حول الطلب على الرعاية الصحية في النرويج واستخدم للتنبؤ بالعدد المتوقع لدخول المستشفيات ومعدلات إشغال الأسرة في ظل سيناريوهات مختلفة تتعلق بوباء COVID-19 [11].

في دراسة أخرى "تنبؤ وتحليل الاستهلاك السنوي للكهرباء لتركيا باستخدام نماذج ARIMA و VARIMA" قام بها A.Coban و M.K. تم تدريب النماذج على البيانات التاريخية حول استهلاك الكهرباء في تركيا واستخدامها للتنبؤ بمستويات استهلاك الكهرباء في المستقبل في ظل سيناريوهات مختلفة [12]. في دراسة ثالثة "تنبؤ السلاسل الزمنية المالية مع نماذج ARIMA و GARCH" بقلم ب. ساداتبور وس. العوائ د اليومية لمؤشر S&P 500. تم تدريب النماذج على البيانات التاريخية على مؤشر S&P 500 واستخدمت للتنبؤ بالعائدات المستقبلية في ظل سيناريوهات مختلفة [13].

وفي جانب آخر من الطرق المستخدمة في مجال البحث، هو استخدام الذكاء الاصطناعي من خلال خوارزميات تعلم الآلة. التعلم الآلي هو مجموعة فرعية من الذكاء الاصطناعي تتضمن بناء خوارزميات ونماذج يمكنها التعلم والتحسين من البيانات دون أن تتم برمجتها بشكل صريح. بعبارة أخرى، بدلاً من أن تتم برمجتها بمجموعة من القواعد التي يجب اتباعها، يتم تغذية نموذج التعلم الآلي بالبيانات ويستخدم تلك البيانات لتعلم الأنماط والعلاقات في البيانات، مما يسمح لها بعمل تنبؤات أو قرارات بشأن بيانات جديدة غير مرئية.

فلقد تم استخدام الشبكات العصبية الاصطناعية (Artificial Neural Networks (ANN) في عدة دراسات في هذا المجال. وهي نوع من نماذج التعلم الآلي التي يمكن استخدامها لمهام التعلم الخاضعة للإشراف وغير الخاضعة للإشراف. وهي تتكون من طبقات متعددة من العقد المترابطة، ويمكن أن تتعلم التعرف على الأنماط في البيانات من خلال التدريب. تم استخدام الشبكات العصبية الاصطناعية على نطاق واسع في أبحاث التعرف على السلوك البشري، وقد أظهرت نتائج واعدة في مجموعة متنوعة من السياقات. الذي ظهر ضمن هذه الأنماط. ومع ذلك، فإن مجموعة البيانات الخاصة بهم صغيرة ويمكن أن يؤدي المزيد من البيانات إلى تغيير النتائج بسبب سلوك ANN، والتي يمكنها تكييف طبقاتها المخفية للاحتفاظ بمعلومات إضافية إذا لم يتم العثور على مثال يناسب البنية الحالية.

في الدراسات [15][16]، تم استخدام الشبكات العصبية الاصطناعية لتصنيف أنواع مختلفة من السلوك بناءً على البيانات التي تم جمعها من أجهزة الاستشعار مثل مقاييس التسارع والجيروسكوب ومقاييس المغناطيسية. وجد الباحثون أن الشبكات العصبية الاصطناعية كانت فعالة في التعرف على الأنماط في بيئات المستشعر وتصنيف الأنواع المختلفة من السلوك، على الرغم من اختلاف أداء النماذج اعتماداً على المهمة المحددة وجودة بيانات التدريب. بشكل عام، أظهرت ANNs واعدة كأداة للتعرف على السلوك البشري، ولكن هناك حاجة إلى مزيد من البحث لتحسين دقة ومتانة هذه النماذج.

كما أجرى كل من Y. Chen و K. Lu و D. Zhang مراجعة للبحوث حول التعرف على السلوك البشري باستخدام أجهزة استشعار يمكن ارتداؤها. ركزوا على الدراسات التي استخدمت تقنيات التعلم الآلي لتصنيف أنواع مختلفة من السلوك بناءً على البيانات التي تم جمعها من أجهزة الاستشعار مثل مقاييس التسارع والجيروسكوب ومقاييس المغناطيسية. ووجد الباحثون أن أشجار القرار وآلات الدعم Support Vector Machine (SVM) والشبكات العصبية كانت من بين أكثر خوارزميات التعلم الآلي شيوعاً في التعرف على السلوك البشري. وجدوا أيضاً أن استخراج الميزات، والذي يتضمن اختيار واستخراج الميزات ذات الصلة من بيانات المستشعر، كان خطوة حاسمة في عملية التعرف على السلوك [17].

تستخدم تقنيات التعلم الآلي في مجموعة واسعة من التطبيقات، بما في ذلك التعرف على الصور والكلام ومعالجة اللغة الطبيعية واكتشاف الاحتيال وأنظمة التوصية [18].

وفي نموذج آخر، فإن نظام الاستدلال العصبي الضبابي التكيفي Adaptive Neuro Fuzzy Inference System (ANFIS) هو نوع من نماذج التعلم الآلي التي تجمع بين قوة المنطق الضبابي والشبكات العصبية لإنشاء نموذج هجين يمكنه التعامل مع العلاقات المعقدة وغير الخطية في البيانات.

المنطق الضبابي هو إطار رياضي يتعامل مع معلومات غير مؤكدة أو غامضة، مثل اللغة البشرية أو التقييمات الذاتية. من ناحية أخرى، الشبكات العصبية هي أنظمة حوسبة مستوحاة من بنية ووظيفة الدماغ البشري الذي يمكنه تعلم الأنماط والعلاقات في البيانات.

تستخدم نماذج ANFIS مجموعة من القواعد لتمثيل العلاقة بين متغيرات الإدخال والإخراج، بحيث يتم دمج هذه القواعد مع شبكة عصبية تتعلم المعلمات المثلى للقواعد الغامضة بناءً على مجموعة بيانات التدريب.

يتمتع نموذج ANFIS بالعديد من المزايا، بما في ذلك قدرته على التعامل مع العلاقات المعقدة وغير الخطية في البيانات، وقابليته للتفسير، وقدرته على التعامل مع البيانات العددية والفئوية.

تم استخدام نماذج ANFIS في تطبيقات مختلفة، بما في ذلك أنظمة التحكم والتنبؤ بأسعار الأسهم والتشخيص الطبي واكتشاف الأخطاء في العمليات الصناعية. تم استخدام نماذج ANFIS في تطبيقات مختلفة، بما في ذلك تحليل أنشطة بيانات الحياة اليومية (ADLs) (لفهم السلوك البشري وتحسين نتائج الرعاية الصحية).

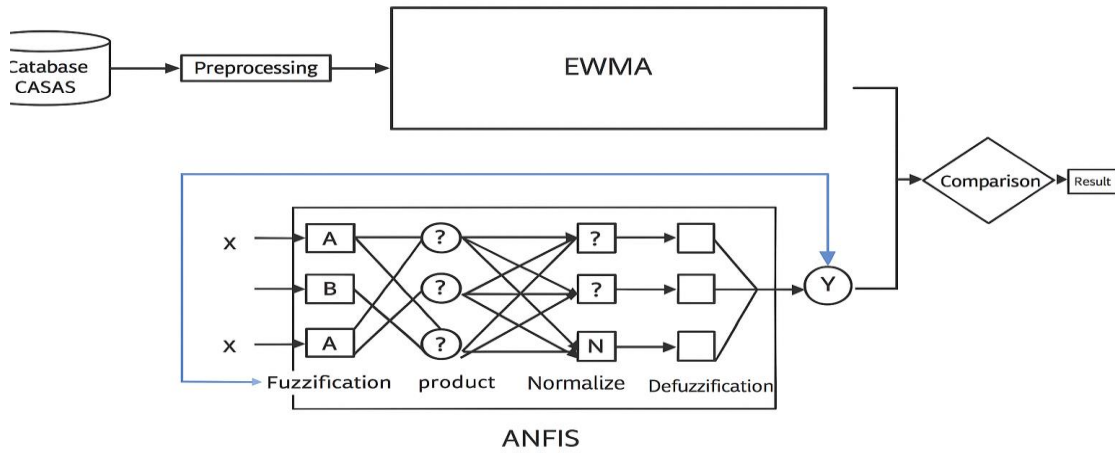
أحد الأمثلة على نموذج ANFIS المستخدم في ADL هو دراسة أجراها Jin et al (2019) بشأن تحليل السلوك البشري باستخدام بيانات مستشعر المنزل الذكي. في هذه الدراسة، تم استخدام نماذج ANFIS للتنبؤ بالأنشطة التي يقوم بها كبار السن بناءً على بيانات الاستشعار التي تم جمعها من منازلهم. هدفت الدراسة إلى تحسين نتائج الرعاية الصحية للأفراد المسنين من خلال تحديد علامات الإنذار المبكر للتدهور الصحي وتقديم رعاية شخصية.

تم تدريب نموذج ANFIS باستخدام بيانات الاستشعار التي تم جمعها من المنازل الذكية، والتي تضمنت معلومات عن الأنشطة التي يقوم بها الأفراد، مثل المشي والجلوس والنوم. كان نموذج ANFIS قادراً على التنبؤ بدقة بالأنشطة التي يقوم بها الأفراد بدرجة عالية من الدقة، وتم استخدام النتائج لتوفير رعاية شخصية للأفراد بناءً على احتياجاتهم الصحية [19].

ويعد استخدام مثل هذه الطرق في هذا البحث إضافة للتنبؤ بالسلوك البشري وإظهار السلوك غير الطبيعي والذي يمكن أن يكون مؤشراً على تغير غير طبيعي في الحالة الصحية للشخص الذي تتم مراقبته من خلال شبكة من الحساسات الاستشعارية.

### 3. منهجية البحث

تم في هذا البحث وضع طريقة لتحليل السلوك اليومي لإنسان يعيش في منزل ذكي بعد أن تم جمع بيانات تخص حركته اليومية عن طريق مستشعرات تم تنصيبها في المنزل تقوم بمراقبة الحركة اليومية له. تمت معالجة البيانات الأولية وتحويلها إلى قيم زمنية تمثل المدة الزمنية لكل حركة مثل البقاء مدة معينة في غرفة النوم والتي كانت في الأصل تأخذ شكل الوقت والتي تعتبر بيانات ثنائية لأنها تعتمد على تشغيل وإيقاف تشغيل المستشعر. بعد ذلك تم إدخال البيانات المعالجة على النموذجين المتوسط المتحرك لتوقع النشاط ونظام الاستدلال الضبابي القائم على الشبكات العصبية والمقارنة بين النموذجين في التنبؤ بحدوث الحركات غير العادية في سلوك الانسان. الشكل رقم (1) يعرض المنهجية المتبعة في المشروع.



الشكل رقم (1) المنهجية المتبعة في البحث

#### 1.3 وصف البيانات المستخدمة في المشروع:

مجموعة بيانات CASAS للمنازل الذكية هي مجموعة شاملة وواقعية من بيانات الأنشطة المستندة إلى أجهزة الاستشعار، والتي جُمعت من 189 منزلاً ذكياً على مدار 18 عامًا (2007-2024). طُوّر هذا البحث من قِبل مختبر CASAS بجامعة ولاية واشنطن، وهو مصمم لدعم الأبحاث في مجال الذكاء البيئي، والتعرف على الأنشطة، وتحليل أنماط السلوك في البيئات السكنية.

• أنواع البيانات:

o مستشعرات الحركة (PIR)

o مستشعرات الأبواب والأشياء (التلامسات المغناطيسية)

o تسميات الأنشطة المُعلّقة (مثل: الطبخ، النوم، الاستحمام).

• الهيكل: يتضمن كل سجل:

o الطابع الزمني

o مُعرّف المستشعر

o رسالة الحدث (مثل: تشغيل/إيقاف، فتح/إغلاق)

o تسمية نشاط اختيارية (للبيانات المُعلّقة) [20].

• معالجة البيانات مسبقاً:

- تنظيف البيانات

• إزالة الصفوف التي تحتوي على قيم مفقودة أو مشوهة.

• تأكد من احتواء عمود "الرسالة" على القيم الصحيحة فقط (مثل: تشغيل، إيقاف، فتح، إغلاق).

- ترميز البيانات الفئوية

• تحويل الأعمدة النصية إلى رقمية باستخدام برامج الترميز:

o معرف المستشعر ← أعداد صحيحة فريدة

o الرسالة ← الحالات المشفرة

o النشاط (إذا كان مُسمّى) ← تسميات النشاط المشفرة

- تسمية البيانات
- مطابقة أحداث المستشعر مع الأنشطة المُسمّاة باستخدام طوابع زمنية للبدائية والنهائية.
- يُضاف عمود "نشاط" جديد لتمثيل الإجراء المُنفذ خلال كل نافذة حدث.
- إنشاء تسلسلات (نوافذ منزلة)
- تقسيم البيانات إلى تسلسلات (مثلاً، كل 10 أحداث) لتدريب النماذج القائمة على التسلسلات.
- يُصبح كل تسلسل مُدخلًا واحدًا للنموذج.
- تقسيم التدريب والاختبار
- قسّم مجموعة البيانات إلى مجموعات فرعية للتدريب والاختبار لتقييم أداء النموذج.

الجدول رقم (1) عينة من البيانات الحقيقية للمنزل الذكي.

قيمة الحساس	الموقع	نوع الحساس	الوقت والتاريخ
00011	Living Room	PIR	2015 - 01 - 11 10 : 04 : 17.756
00011	Master Bedroom	PIR	2015 - 01 - 11 10 : 05 : 03.566
00011	Kitchen	PIR	2015 - 01 - 11 10 : 07 : 05.542

### 2.3 المتوسط المرجح المتحرك الآسي لتوقع النشاط

يستند المتوسط المتحرك لتوقع النشاط على المتوسط المتحرك الآسي الموزون EWMA للتنبؤ بالقيمة التالية للنشاط. ويتم استخدامه لتحليل نقاط البيانات عن طريق إنشاء سلسلة من المتوسطات. باختصار، يعطي EWMA أوزانًا مختلفة لنقاط البيانات في مواقع مختلفة. يمكن أن يكون EWMA عبارة عن مرشح استجابة نبضي لانتهائي يطبق عوامل ترجيح تتخفف أضعافًا مضاعفة ولا تصل أبدًا إلى الصفر [21]، [22]. يمكن حساب EWMA لسلسلة P بشكل متكرر باستخدام المعادلة 1، والتي يمكن التعبير عنها بمصطلحات التحليل الفني لإظهار خطوات EWMA نحو أحدث نقطة مرجعية، باستخدام نسبة مختلفة (في كل مرة).

$$(1) \quad EWMA_{new} = EWMA_{old} + \beta (P_{current} \times EWMA_{old})$$

حيث:

يمثل  $\beta$  درجة انخفاض الترجيح، وهو عامل تجانس ثابت بين 0 و 1. يقوم أعلى  $\beta$  بخصم الملاحظات الأقدم بشكل أسرع.

$EWMA_{new}$  القيمة الجديدة ل EWMA.

$EWMA_{old}$  القيمة القديمة ل EWMA.

$P_{current}$  هو قيمة البيانات في الوقت الحالي.

يمكن تهيئة EWMA بطرق مختلفة؛ الطريقة الأكثر شيوعًا هي ضبط EWMA1 على  $P_1$ . يمكن تهيئته باستخدام متوسط أول 4 أو 5 نقاط بيانات. من المهم جدًا تهيئة EWMA1 لأن تأثيره على المتوسط المتحرك الناتج يعتمد على قيم اختيار قيم صغيرة لـ  $\beta$  يجعل اختيار EWMA1 أكثر أهمية نسبيًا من قيم الكبيرة. ستعمل القيم الأعلى على خصم الملاحظات القديمة بشكل أسرع [23].

3.3 نظام الاستدلال العصبي الضبابي التكيفي (ANFIS).

### 3.3 نظام الاستدلال الضبابي الشبكي

(ANFIS) هو نموذج يدمج بين الاستدلال الضبابي والشبكات العصبية لتحسين أداء التحليل والتنبؤ في المسائل غير الواضحة وغير الدقيقة. يتم استخدام ANFIS لتعديل وزن القواعد الضبابية باستخدام تقنيات التعلم العصبي، مما يتيح له القدرة على تكيف نفسه وتحسين النموذج النهائي بناءً على البيانات المتاحة. يوفر ANFIS إطارًا عمليًا لتحليل البيانات وتوقع السلوك في بيئات مثل بيئة الذكاء البيئي. يعتبر ANFIS أداة قوية لتحقيق دقة التنبؤات وتحليل البيانات في مجالات مختلفة تعاني من عدم الدقة والغموض.

مثال لفهم آلية عمل نظام ANFIS لنفترض أن لدينا بيئة ذكية مثل غرفة في منزل تجمع بيانات حساسات متعددة مثل مستشعرات الحركة ومستشعرات درجة الحرارة ومستشعرات الإضاءة. هدفنا هو التنبؤ بسلوك الأشخاص في الغرفة، مثل مستوى النشاط أو الراحة.

الآلية تتضمن الخطوات التالية:

تجميع البيانات: يتم تجميع البيانات من مستشعرات الحركة ودرجة الحرارة والإضاءة في الغرفة. يتم تسجيل القراءات بشكل منتظم وتخزينها للاستخدام في التحليل.

تحويل المتغيرات: يتم تحويل قراءات المستشعرات إلى قوائم ضبابية. على سبيل المثال، يمكن تحويل مستوى الحركة إلى قوائم ضبابية مثل "لا حركة" و"حركة خفيفة" و"حركة مكثفة"، وذلك لتمثيل التغيرات غير الدقيقة في مستوى الحركة.

بناء القاعدة الضبابية: يتم بناء قاعدة القواعد الضبابية باستخدام المعرفة والخبرة المتاحة. يتم تحديد القواعد الشرطية وقواعد النتائج بناءً على المعرفة المتاحة، مثل "إذا كانت درجة الحرارة مرتفعة ولا يوجد حركة، فقد يكون الشخص غير نشط" و"إذا كانت درجة الحرارة منخفضة وهناك حركة مكثفة، فقد يكون الشخص نشيطاً".

تدريب النموذج: يتم تدريب النموذج باستخدام البيانات المتاحة وخوارزمية انتشار الخطأ العكسية. يتم ضبط وزن القواعد الضبابية وتحديد دقتها وأهميتها في التنبؤ بسلوك الأشخاص في الغرفة.

التحليل والتنبؤ: بعد تدريب النموذج، يتم استخدامه لتحليل البيانات الجديدة والتنبؤ بسلوك الأشخاص في الغرفة. يستنتج النموذج النتائج من خلال تطبيق قواعد الاستدلال الضبابي والمعلومات المتاحة من المستشعرات.

التحسين والتكيف: يمكن لنظام ANFIS تحسين أداؤه لتكييف نفسه بناءً على الملاحظات والتغيرات في البيئة. يمكن أن يستخدم النموذج المحسن لتعديل قواعد الاستدلال الضبابي لتحسين الأداء التنبؤي.

بهذا الشكل، يمكننا استخدام نظام الاستدلال الضبابي القائم على الشبكة التكيفية لتحليل البيانات المستشعرة وتنبؤ سلوك الأشخاص في بيئة ذكية مثل الغرفة. يمكن استخدام هذه التنبؤات في تحسين تجربة المستخدم، مثل تعديل إضاءة الغرفة أو ضبط درجة الحرارة بناءً على احتياجات الأفراد في البيئة.


من المهم أن نلاحظ أن هذا مجرد مثال توضيحي وأن تنبؤ السلوك البشري في بيئة ذكية ينطوي على تحديات متعددة، بما في ذلك جمع البيانات الدقيقة وتحليلها بشكل فعال [24][25].

#### 4. نتائج البحث

##### 1.4 نتائج ANFIS.

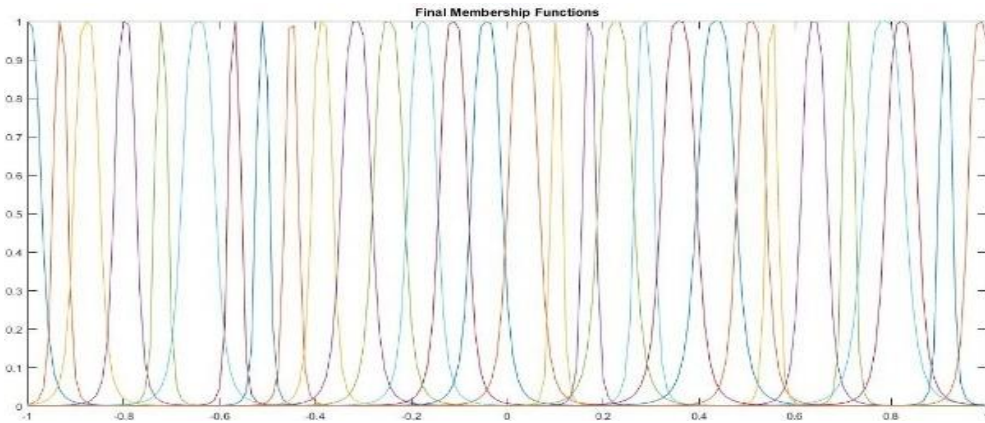
في هذا العمل، يتم استخدام ANFIS للتنبؤ بقيمة النشاط بناءً على البيانات التاريخية المتوفرة لدينا. كما هو موضح في نموذجنا المقترح، من الضروري تحضير البيانات لاستخدامها كسلسلة زمنية. نظرًا لأننا نؤمن بذلك، من الصعب جدًا نمذجة البيانات الثنائية الأصلية أو التنبؤ بها. الخطوة الثانية التي قمنا بها هي استخدام تقنية تحليل الاتجاه لتنعيم كل مجموعة بيانات والحصول على اتجاهها؛ ثم حان وقت ANFIS للتنبؤ بالقيم الجديدة لنقاط البيانات بناءً على مجموعات البيانات المتجانسة. متغيرات الخوارزمية المستخدمة في الدراسة هي عدد مختلف من وظائف العضوية وأنواع مختلفة من الوظائف مثل "gbellmf" و "gauss2mf". يتم استخدام مجموعات بيانات مختلفة في هذا العمل أيضًا باستخدام ANFIS لوقت المدة. يمثل الشكل 2 عينة من نتائجنا لاستخدام ANFIS للتنبؤ ببياناتنا. في هذا المثال، استخدمنا 30 وظيفة عضوية، نوع "gbellmf".





الشكل 2: نتائج التنبؤ باستخدام ANFIS لوقت المدة.

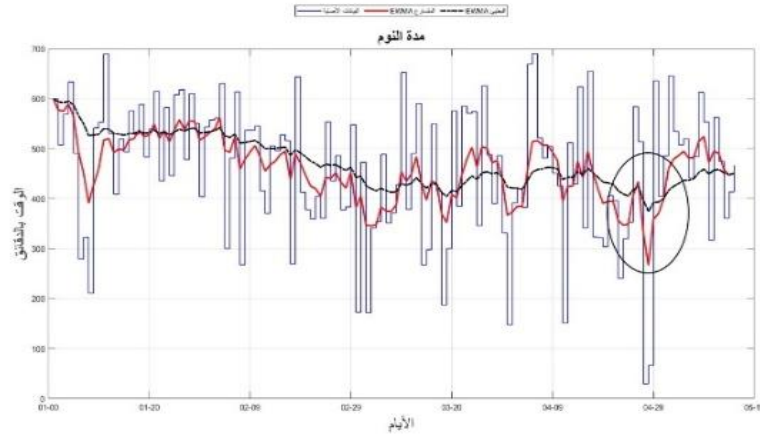
يوضح الشكل 3 وظائف الدالة النهائية المستخدمة في هذا المثال. مجموعة البيانات المستخدمة هنا خاصة بمدة النوم في غرفة النوم.



الشكل 3: وظائف العضوية النهائية المستخدمة في هذا المثال.

#### 2.4 نتائج EWMA

نتائج استخدام EWMA السريع معدل 28 يوما والبطيء بمعدل 7 أيام، فهي تُظهر أن EWMA السريع أكثر حساسية للتغيرات التي قد تحدث في البيانات الأصلية، ويحدث التقاطع عندما تحدث تغيرات تدريجياً أو لأسفل كما هو مبين في الشكل 4.



الشكل 4 عينة من نتائج استخدام EWMA في التنبؤ بمدة النوم بالدقيقة.

يقدم الجدول (2) عينة من نتائج البحث، والذي يحتوي على ثلاثة أعمدة؛ تمثل أحدهما للبيانات الفعلية والعمودين الآخرين يظهران النتائج المتحصل عليها من الطرق المستخدمة في هذا البحث للتنبؤ بالبيانات المتوقعة.

الجدول (2): عينة من نتائج استخدام ANFIS و EWMA مع مجموعة بيانات غرفة النوم لتوقع عدد ساعات النوم بالدقيقة.

البيانات الحقيقية	البيانات التي تم الحصول عليها من EWMA	البيانات التي تم الحصول عليها من ANFIS
450.5	451.65	479.12
492.2	494.67	492.18
489.7	481.95	489.84
458.1	457.76	458.02
451.7	443.10	451.65

من ناحية أخرى، يجب التنويه بأن استخدام ANFIS سيعطي نتائج أفضل إذا كانت البيانات عبارة عن سلسلة زمنية وسيعطي نتائج أقل جودة إذا كانت البيانات أكثر فوضوية أو بيانات ثنائية.

## 5. الاستنتاجات والتوصيات

### 1.5 الاستنتاجات

في هذا البحث، قمنا بالتحقيق في تقنيات التنبؤ التي يمكن تطبيقها على بيانات السلوك البشري. توضح الحلول المقترحة جدوى تفسير هذا النوع من البيانات. ستدعم هذه التقنيات المشرف في الحصول على معلومات واضحة حول وضع المشارك الذي يشغل بيئة ذكية. تعطي نتائج المجربين الذين تم إجراؤهم مؤشراً جيداً على أهمية استخدام تقنيات التنبؤ لتفسير أنشطة البشر.

لاستخدام تقنيات التنبؤ مع هذه البيانات لدينا؛ من الضروري تحضير البيانات أولاً. يشمل إعداد بياناتنا؛ التعامل مع البيانات المفقودة، وتحويل البيانات من ثنائي إلى التنسيق المناسب الذي استخدمناه لاحقاً مع تقنيات التنبؤ واستخراج البيانات الدقيقة لكل ميزة أو نشاط. تقدم تقنيات التنبؤ المستخدمة في هذه الورقة نتائج جيدة من حيث شرح النشاط. يمكنهم تحديد الموقف التالي والتنبؤ به أو توقع اتجاه الاتجاه في كل مجموعة بيانات. يمكنهم عرض مزيد من المعلومات حول استخدامات كل جهاز استشعار في وقت محدد مثل الحد الأدنى لمدة الاستخدام ومتوسط مدة الاستخدام ومدة الاستخدام القصوى.

## 2.5 التوصيات

يوصى بالتطرق لهذه الموضوعات ودراستها بشكل أكثر تفصيلاً واستخدام عدد من البيانات المختلفة للوصول إلى دقة أفضل. كما أوصي باستخدام طرق أخرى مثل طرق التعلم العميق ومقارنتها مع طرق تعلم الآلة والطرق الإحصائية الأخرى بغية الحصول على أدق النتائج وخاصة أن هذه النتائج تتعلق بحياة الإنسان.

## المراجع

- [1] Connolly, D., Garvey, J., & McKee, G. (2017). Factors associated with ADL/IADL disability in community dwelling older adults in the Irish longitudinal study on ageing (TILDA). *Disability and rehabilitation*, 39(8), 809-816.
- [2] Kumar, P., Chauhan, S., & Awasthi, L. K. (2024). Human activity recognition (har) using deep learning: Review, methodologies, progress and future research directions. *Archives of Computational Methods in Engineering*, 31(1), 179-219.
- [3] Dhiman, C., & Vishwakarma, D. K. (2019). A review of state-of-the-art techniques for abnormal human activity recognition. *Engineering Applications of Artificial Intelligence*, 77, 21-45.
- [4] Diraco, G., Rescio, G., Siciliano, P., & Leone, A. (2023). Review on human action recognition in smart living: Sensing technology, multimodality, real-time processing, interoperability, and resource-constrained processing. *Sensors*, 23(11), 5281.
- [5] Kolkar, R., & Geetha, V. (2021, October). Human activity recognition in smart home using deep learning techniques. In *2021 13th International conference on information & communication technology and system (ICTS)* (pp. 230-234). IEEE.
- [6] Xue, T., & Liu, H. (2021, July). Hidden Markov Model and its application in human activity recognition and fall detection: A review. In *International conference in communications, signal processing, and systems* (pp. 863-869). Singapore: Springer Singapore.
- [7] Deng, Q., & Söffker, D. (2021). A review of HMM-based approaches of driving behaviors recognition and prediction. *IEEE Transactions on Intelligent Vehicles*, 7(1), 21-31.
- [8] Roy, P. P., Kumar, P., & Kim, B. G. (2021). An efficient sign language recognition (SLR) system using Camshift tracker and hidden Markov model (hmm). *SN Computer Science*, 2(2), 79.
- [9] Lucey, P., Cohn, J. F., Kanade, T., Saragih, J., Ambadar, Z., & Matthews, I. (2010). The Extended Cohn-Kanade Dataset (CK+): A complete dataset for action unit and emotion-specified expression. *Computer Vision and Image Understanding*, 114(1), 36-85.
- [10] Chouhayebi, H., Mahraz, M. A., Riffi, J., Tairi, H., & Alioua, N. (2024). Human Emotion Recognition Based on Spatio-Temporal Facial Features Using HOG-HOF and VGG-LSTM. *Computers*, 13(4), 101.
- [11] Kim, J., Kim, H., & Lee, K. M. (2012). Emotion recognition using a hybrid Gaussian mixture model and support vector machine. *IEEE Transactions on Neural Networks and Learning Systems*, 23(6), 942-951.
- [12] Bråthen, A., et al. (2020). Forecasting the impact of COVID-19 on healthcare demand in Norway using an ARIMA model. *BMC Medical Informatics and Decision Making*, 20(1), 116.

- [13] Çoban, A., & Göçer, M. K. (2017). Forecasting and analyzing the annual electricity consumption of Turkey using ARIMA and VARIMA models. *Energies*, 10(7), 936.
- [14] Saadatpour, P., & Al-Sultan, S. K. S. (2014). Forecasting financial time series with ARIMA and GARCH models. *Journal of Applied Statistics*, 41(12), 2635-2650.
- [15] Baccouche, F. Mamalet, C. Wolf, and P. Garcia. (2011). "Human behavior recognition using spatiotemporal features and deep learning." *IEEE Transactions on Image Processing*, vol. 20, no. 3, pp. 695-704.
- [16] Demrozi, F., Turetta, C., Machot, F. A., Pravadelli, G., & Kindt, P. H. (2023). A comprehensive review of automated data annotation techniques in human activity recognition. *arXiv preprint arXiv:2307.05988*.
- [17] Kılıç, Ş., Kaya, Y., & Askerbeyli, İ. (2021). A new approach for human recognition through wearable sensor signals. *Arabian Journal for Science and Engineering*, 46(4), 4175-4189.
- [18] Y. Chen, K. Lu, and D. Zhang, (2018). "Human behavior recognition using wearable sensors: A review," *IEEE Access*, vol. 6, pp. 57,918-57,934.
- [19] Géron, A. (2022). *Hands-on machine learning with Scikit-Learn, Keras, and TensorFlow: Concepts, tools, and techniques to build intelligent systems*. "O'Reilly Media, Inc."
- [20] Cook, D.J.; Crandall, A.S.; Thomas, B.L.; Krishnan, N.C. (2012). CASAS: A smart home in a box. *Computer*, 46, 62–69.
- [21] Walia, N., Singh, H., & Sharma, A. (2015). ANFIS: Adaptive neuro-fuzzy inference system-a survey. *International Journal of Computer Applications*, 123(13).
- [22] Holt, Charles C. (2004). Forecasting seasonals and trends by exponentially weighted moving averages. *International journal of forecasting*. Elsevier, 20(1): 5–10.
- [23] Gardner Jr, E. S. (2006). Exponential smoothing: The state of the art—Part II. *International journal of forecasting*, 22(4), 637-666.
- [24] Elbayoudi, A., Lotfi, A., Langensiepen, C., & Appiah, K. (2017, June). Trend analysis techniques in forecasting human behaviour evolution. In *Proceedings of the 10th International Conference on PErvasive Technologies Related to Assistive Environments* (pp. 293-299).
- [25] Karaboga, D., & Kaya, E. (2019). Adaptive network based fuzzy inference system (ANFIS) training approaches: a comprehensive survey. *Artificial Intelligence Review*, 52, 2263-2293.