

## نموذج تعلم آلة قابل للتفسير للكشف عن التوتر النفسي اعتماداً على خصائص تباين معدل ضربات القلب

\* هازار حاتم موسي

(تاريخ الإيداع ٢٠٢٦/١/١٨ . قُبِلَ للنشر في ٢٠٢٦/٢/٢٣)

□ ملخص □

يُعد كشف التوتر النفسي (Stress Detection) باستخدام تقنيات تعلم الآلة من المجالات البحثية الواعدة نظراً للتأثير المباشر للتوتر على الصحة النفسية والجسدية والأداء البشري، خاصة في بيئات العمل الذكية. تهدف هذه الدراسة إلى تطوير نموذج قابل للتفسير لكشف حالات التوتر اعتماداً على بيانات فيزيولوجية مأخوذة من مجموعة البيانات SWELL Knowledge Work Stress Dataset. تم اعتماد نموذج XGBoost نظراً لملاءمته العالية لطبيعة البيانات الطبية الفيزيولوجية، والتي تتسم بعلاقات غير خطية معقدة وتداخل بين المؤشرات الحيوية المختلفة. تم تقييم أداء النموذج باستخدام مجموعة من المقاييس القياسية، شملت مصفوفة الارتباك ومنحنيات ROC-AUC و Precision-Recall، بما يوفر تقييماً شاملاً لجودة التصنيف. أظهرت النتائج التجريبية أن النموذج المقترح حقق أداء تصنيف مرتفع ومتوازن عبر فئات الإجهاد الثلاث، حيث بلغت الدقة العامة (F1-score) 95%. كما أظهر النموذج قدرة تمييز شبه مثالية، إذ بلغت قيم  $AUC-ROC = 1.00$  لجميع الفئات. وإلى جانب الأداء التنبؤي، تم توظيف تقنيات الذكاء الاصطناعي القابل للتفسير (XAI) باستخدام SHAP لتحليل مساهمة الخصائص المختلفة في قرارات النموذج، مما أتاح فهماً معمقاً للعوامل الفيزيولوجية الأكثر تأثيراً في كشف التوتر. تؤكد هذه النتائج أن النموذج المقترح يجمع بين الدقة العالية وقابلية التفسير، مما يعزز موثوقيته ويدعم إمكانية اعتماده في التطبيقات الواقعية وأنظمة دعم القرار الصحي.

**الكلمات المفتاحية:** كشف التوتر النفسي، تعلم الآلة، خوارزميات التعلم المعزز بالأشجار، الذكاء الاصطناعي القابل للتفسير، تقنية SHAP.

## Explainable Machine Learning Model for Stress Detection Using Heart Rate Variability Features

\*Hazar Hatem Moussi

(Received 18/1/2026 . Accepted 23/2/2026)

□ ABSTRACT □

Stress detection using machine learning techniques is considered one of the most promising research areas due to the direct impact of stress on mental and physical health as well as human performance, particularly in intelligent work environments. This study aims to develop an explainable model for stress detection based on physiological data obtained from the SWELL Knowledge Work Stress Dataset. The XGBoost model was adopted due to its high suitability for physiological medical data, which have complex nonlinear relationships and interactions among different biomarkers.

The model's performance was evaluated using a set of standard metrics, including the confusion matrix, ROC–AUC curves, and precision–recall curves, which provided a comprehensive assessment of classification quality. Experimental results demonstrated that the proposed model achieved high and well-balanced classification performance across the three stress categories, with an overall F1-score of 95%. Moreover, the model exhibited near-perfect discriminative capability, achieving AUC-ROC values of 1.00 for all classes.

In addition to predictive performance, explainable artificial intelligence (XAI) techniques were employed using SHAP to analyze the contribution of different features to the model's decisions, enabling an in-depth understanding of the most influential physiological factors in stress detection. These findings confirm that the proposed model effectively combines high accuracy with interpretability, enhancing its reliability and supporting its potential adoption in real-world applications and healthcare decision support systems.

**Keywords:** Stress Detection, Machine Learning, XGBoost, Explainable Artificial Intelligence, SHAP.

## 1. المقدمة:

يُعدّ التوتر النفسي أحد أبرز التحديات الصحية المعاصرة، نظراً لتأثيره المباشر في الأداء المعرفي والصحة الجسدية وجودة اتخاذ القرار في البيئات المهنية والتعليمية. وقد أظهرت الدراسات أن التعرض المزمن أو المتكرر لحالات التوتر يرتبط بانخفاض الكفاءة الإدراكية وزيادة مخاطر الاضطرابات القلبية، بالإضافة إلى تأثيراته السلبية على الإنتاجية والرفاه العام. ورغم الانتشار الواسع لأدوات كشف التوتر التقليدية المعتمدة على التقييمات الذاتية والاستبيانات النفسية، فإن هذه الأساليب تعاني من قيود جوهرية تتعلق بالتحيز الإدراكي وضعف الدقة الزمنية وعدم القدرة على الرصد المستمر، مما حدّ من فعاليتها في التطبيقات الواقعية والسريية.

نظراً لقصور طرق كشف التوتر التقليدية، اتجهت الأبحاث الحديثة نحو استثمار البيانات الفيزيولوجية بوصفها مصدراً أكثر دقة وموضوعية لرصد التوتر النفسي، الأمر الذي جعل تطوير نماذج تعلم آلة فعالة للكشف عن التوتر أحد المحاور البحثية الرئيسة في مجالي الصحة الرقمية والذكاء الاصطناعي الطبي. وقد أثبتت الأدبيات العلمية أن الإشارات الحيوية، ولا سيما معدل ضربات القلب (Heart Rate - HR) وتباين معدل ضربات القلب (Heart Rate Variability - HRV)، والنشاط الكهربائي للجلد (Electrodermal activity - EDA)، تعكس استجابات فسيولوجية مباشرة لحالات الضغط النفسي، مما يجعلها مدخلات موثوقة لنماذج التعلم غير الخطية القادرة على التقاط الأنماط المعقدة والكامنة في هذه الإشارات، متجاوزةً القيود المعروفة لأساليب التقييم الذاتي [1].

أظهرت خوارزميات التعلم المعزّز بالأشجار وعلى رأسها (Extreme Gradient Boosting - XGBoost)، كفاءة عالية في نمذجة العلاقات غير الخطية بين المؤشرات الفيزيولوجية وحالات التوتر، خاصةً عند دمجها بتقنيات الذكاء الاصطناعي القابل للتفسير (XAI) مثل (SHapley Additive exPlanations - SHAP)، التي أسهمت في تحويل هذه النماذج من صناديق سوداء إلى أدوات تحليلية قابلة للفهم السريي واتخاذ القرار الطبي [2, 3].

## 2. الدراسات المرجعية:

وفي إطار توسيع نطاق البيانات الفيزيولوجية المستخدمة في تطوير نماذج كشف التوتر، قدّمت دراسة حديثة مجموعة البيانات (Novel Wearable LDF/FS) متعددة الوسائط واسعة النطاق، حيث جُمعت بيانات ١٣٢ متطوعاً باستخدام مجسات قياس تدفق الدم بالليزر دوبلر (Laser Doppler Flowmetry - LDF) ومجسات مطيافية الفلورة (Fluorescence Spectroscopy - FS)، بوصفها مقاربة غير جراحية وقابلة للارتداء للتنبؤ بحالات الصحة النفسية، بما في ذلك التوتر والقلق [4]. قد أظهرت النتائج تفوق نموذج LightGBM محققاً مساحة تحت المنحنى (AUC - ROC) بلغت ٠,٧١٦٨، مع توظيف تقنيات XAI للكشف عن ارتباطات ديموغرافية وفيزيولوجية بالتوتر. وعلى الرغم من أهمية هذا العمل من حيث حجم البيانات وتنوعها الجغرافي، إلا أن تركيزه انصبّ على مؤشرات الدورة الدموية الدقيقة أكثر من إشارات HRV المرتبطة مباشرة بالجهد المعرفي.

من جهة أخرى، أثبتت دراسة منهجية موسّعة أن التعرف على الحالات الفيزيولوجية المختلفة، بما في ذلك التوتر والعبء المعرفي والنشاط البدني يُعد بطبيعته عملية غير خطية، حيث تفوقت النماذج غير الخطية بوضوح على النماذج الخطية عند تقييمها على ثلاث مجموعات بيانات عامة جُمعت من ٧٠ متطوع باستخدام جهاز Empatica E4 [5]. أكدت الدراسة أن دمج أنماط متعددة من البيانات مثل النشاط الكهربائي للجلد ودرجة الحرارة

والتسارع يُحسن من متانة النماذج التي تراوحت دقتها بين ٨٩ و ٩٨%، غير أن الاعتماد على بيانات الحياة اليومية حدّ من مستوى التحكم التجريبي، مما يصعب عزل تأثير التوتر المعرفي بشكل دقيق. ركزت عدة دراسات على مجموعة بيانات SWELL-KW بوصفها بيئة تجريبية خاضعة للرقابة لرصد التوتر أثناء أداء مهام معرفية، حيث شملت ٢٥ متطوعاً وأكثر من ٤٠٠ ألف سجل. أظهرت إحدى الدراسات تحقيق دقة تصنيف كاملة (١٠٠%) لثلاث حالات إجهاد متميزة هي: انعدام الإجهاد وضغط الوقت والمقاطعة باستخدام نماذج الغابة العشوائية (Random Forest) وآلة متجهات الدعم (Support Vector Machine - SVM) وخوارزمية الجيران الأقرب (K-Nearest Neighbors - KNN)، بالاعتماد حصراً على خصائص HRV المستخرجة من سجلات تخطيط كهربائية القلب (ECG - Electrocardiogram) [6]. تدعم هذه النتائج الدور المحوري لتقلب معدل ضربات القلب كمؤشر حيوي عالي الحساسية، إلا أن محدودية التحليل التفسيري للنماذج المستخدمة تُبقي قرارات التصنيف في إطار الصندوق الأسود.

بالاعتماد على مجموعة البيانات SWELL-KW نفسها، بيّنت دراسة أخرى إمكانية الفصل بدقة شبه مثالية بين التأثيرات الفيزيولوجية الناجمة عن ضغوط العمل وتلك المرتبطة بعدم الراحة باستخدام خصائص HRV، محققة دقة بلغت ٩٩,٢٥% وتذكراً (Recall) قدره ٩٩,٧٥% [7]. رغم أهمية هذه النتائج في تصميم أنظمة ذكية لإدارة البيئة والرفاهية، فإن التركيز انصبّ على التمييز بين مصادر الضغط أكثر من تفسير آليات اتخاذ القرار داخل النموذج.

وعلى مستوى التطبيقات الواقعية واسعة النطاق، أظهرت دراسات أخرى جدوى استخدام الأجهزة القابلة للارتداء في رصد التوتر خارج المختبر. فقد استعرضت دراسة استخدمت مجموعة البيانات (In-the-wild) القائمة على جمع البيانات باستخدام خاتم Oura من ١٠٣ طلاب جامعيين إمكانية الكشف الجماعي عن أنماط التوتر لدى طلاب الجامعات دون المساس بالخصوصية الفردية، وعلى الرغم من أن الدراسة لم تستخدم مقاييساً عديدة للدقة، إلا أن أنماط التوتر الدورية المكتشفة كانت متوافقة مع أحداث أكاديمية رئيسية [8].

قدّمت دراسة أخرى نظاماً قائماً على الملابس الذكية (MyWear) باستخدام نموذج آلة متجهات الدعم (SVM) المدرب على مجموعة البيانات SWELL-KW لتحقيق دقة مرتفعة في الكشف عن التوتر واضطرابات نظم القلب، مع دعم المراقبة في الزمن الحقيقي، وقد حققت دقة بلغت ٩٨% [9]. غالباً ما تُقدّم هذه المقاربات التطبيقية تفسيراً محدوداً لقرارات النموذج أو تعتمد على إشارات متعددة على حساب التحليل المتعمق لمؤشرات HRV.

أما بالنسبة للنماذج العميقة، فقد اقترحت دراسة حديثة إطاراً قائماً على شبكات الذاكرة الطويلة قصيرة الأمد (Long Short-Term Memory - LSTM) قابلاً للتفسير للكشف عن التوتر الحاد ضمن نوافذ زمنية قصيرة، حيث تم تدريب الشبكة على مجموعة بيانات تضم ٢٨٠ لحظة توتر مجموعة في المختبر من ٢٨ مشاركاً [10]. حقق النموذج دقة بلغت ٩٨,١٦%، لكن رغم الدقة العالية فإن تعقيد النماذج العميقة ومتطلبات البيانات المرتفعة قد يحدان من اعتمادها في الأنظمة السريرية منخفضة الموارد.

بناءً على ما سبق، يتضح وجود فجوة بحثية قائمة بين تحقيق الأداء التصنيفي المرتفع وتوفير تفسير فيزيولوجي واضح وقابل للاستخدام السريري، لا سيما في البيئات المعرفية الخاضعة للرقابة. ومن هنا، يُقدّم هذا البحث إسهاماً منهجياً يتمثل في اعتماد مجموعة بيانات فيزيولوجية مفتوحة المصدر مصممة خصيصاً لرصد

التوتر أثناء أداء مهام معرفية، مع توظيف نموذج XGBoost كنموذج تصنيف أساسي مدعوم بتحليل SHAP لتقديم تفسير واضح وشفاف لمساهمات خصائص HRV في قرارات النموذج.

### 3. أهمية وأهداف البحث:

تتمثل أهمية هذا البحث في الجمع بين الدقة التنبؤية العالية وقابلية التفسير، وهو ما يعزز ثقة المستخدمين وصناع القرار في الأنظمة الذكية. كما يساهم البحث في دعم الاتجاهات الحديثة نحو تطوير أنظمة كشف توتر موثوقة وقابلة للتطبيق في البيئات الصناعية والطبية والذكية.


يهدف هذا البحث إلى:

- بناء نموذج تعلم آلي فعال لكشف التوتر النفسي اعتماداً على بيانات فيزيولوجية متعددة.
- تقييم أداء نموذج XGBoost باستخدام مقاييس تصنيف متعددة تعكس جودة النموذج من زوايا مختلفة.

- تحليل أخطاء التصنيف باستخدام مصفوفة الارتباك ومنحنيات الأداء.
- تطبيق تقنيات الذكاء الاصطناعي القابل للتفسير لفهم تأثير المتغيرات المدخلة على مخرجات النموذج.

### 4. طرائق البحث وموارده:

تعتمد هذه الدراسة على تطوير إطار متكامل لكشف التوتر النفسي باستخدام تقنيات تعلم الآلة القابلة للتفسير، بالاعتماد على سمات عديدة مستخرجة من مجموعة البيانات المفتوحة المصدر SWELL Knowledge Work Stress، ويبين الشكل (1) المخطط الصندوقي لأهم مراحل العمل خلال هذا البحث.



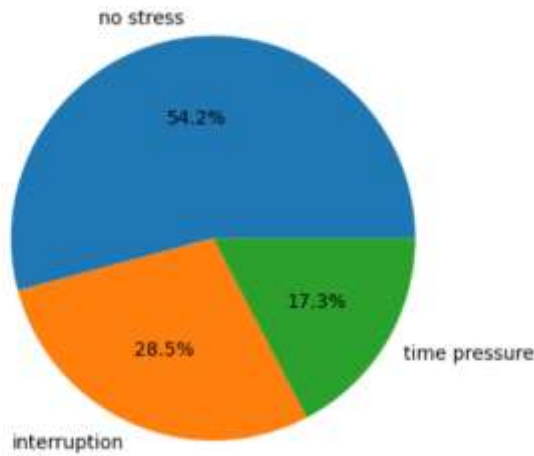
الشكل (1): المخطط الصندوقي لمراحل العمل.

### 5. قاعدة البيانات المستخدمة:

تم استخدام مجموعة بيانات SWELL (SWELL-KW)، وهي مجموعة بيانات تجريبية طُوّرت في معهد علوم الحوسبة والمعلومات بجامعة رادبود، وتهدف إلى دراسة إجهاد العمل (Work Stress) في سياق مهام مكتبية واقعية. شملت التجربة ٢٥ مشاركاً أدوا مهاماً معرفية تحاكي بيئة العمل اليومية، مثل كتابة التقارير وإعداد العروض التقديمية وقراءة البريد الإلكتروني والبحث عن المعلومات، مع تعريضهم لمثيرات إجهاد شائعة في أماكن العمل كالمقاطعات غير المتوقعة وضغط الوقت. مرّ كل مشارك بثلاثة أوضاع عمل مختلفة هي:

1. عدم الإجهاد (no stress)، حيث أُتيح للمشاركين العمل بحرية دون معرفة الحد الزمني الأقصى.
2. ضغط الوقت (time pressure) وفيه تم تقليص زمن إنجاز المهمة إلى ثلثي الزمن الطبيعي.
3. المقاطعة (interruption) حيث تلقّى المشاركون رسائل بريد إلكتروني متكررة أثناء العمل.

استغرقت التجربة كاملةً قرابة ثلاث ساعات لكل مشارك، تم خلالها تسجيل بيانات متعددة الوسائط شملت سجلات استخدام الحاسوب وتعبيرات الوجه ووضعية الجسم وكهربائية الجلد وإشارات تخطيط القلب (ECG)، ويبين الشكل (٢) توزيع أصناف مجموعة البيانات. يركز هذا البحث بشكل أساسي على الإشارات الفيزيولوجية القلبية وبالتحديد تباين معدل ضربات القلب HRV نظراً لارتباطه الوثيق بتنظيم الجهاز العصبي الذاتي واستجابته لحالات التوتر، حيث بالاعتماد على إشارة الفاصل الزمني بين النبضات (IBI) المستخلصة من تخطيط القلب ECG. يوضح الجدول (١) المؤشرات المختارة لتباين معدل ضربات القلب التي تم حسابها من إشارة الفاصل الزمني بين النبضات على مصفوفة متجددة بحجم ٥ دقائق.



الشكل (٢): توزيع أصناف مجموعة البيانات SWELL.

الجدول (١): أوصاف مؤشرات تباين معدل ضربات القلب (HRV) المختارة.

| الوصف المختصر (Short Description)   | مؤشر تباين معدل ضربات القلب (HRV Index) |
|---|---|
| متوسط جميع الفواصل بين قمتين متتالين من موجات R   | MEAN_RR                                 |
| وسيط جميع الفواصل بين قمتين متتالين من موجات R  | MEDIAN_RR                               |
| الانحراف المعياري لجميع الفواصل بين قمتين متتالين من موجات R                                    | SDRR                                    |
| الجذر التربيعي لمتوسط مجموع مربعات الفروق بين الفواصل بين قمتين متتالين من موجات R المتجاورة    | RMSSD                                   |
| الانحراف المعياري لجميع الفروق بين الفواصل بين قمتين متتالين من موجات R المتجاورة               | SDSD                                    |
| نسبة SDRR إلى RMSSD   | SDRR_RMSSD                              |
| معدل ضربات القلب (نبضة في الدقيقة)  | HR                                      |
| النسبة المئوية للفواصل بين قمتين متتالين من موجات R المتجاورة التي تختلف بأكثر من ٢٥ مللي ثانية | pNN25                                   |
| النسبة المئوية للفواصل بين قمتين متتالين من موجات R المتجاورة التي تختلف بأكثر من ٥٠ مللي ثانية | pNN50                                   |
| واصف مخطط بوانكاريه لتباين معدل ضربات القلب قصير الأمد  | SD1                                     |
| واصف مخطط بوانكاريه لتباين معدل ضربات القلب طويل الأمد  | SD2                                     |
| تفرطح جميع الفواصل بين قمتين متتالين من موجات R   | KURT                                    |

|   |                |
|---|----------------|
| التواء جميع الفواصل بين قمتين متتالين من موجات R  | SKEW           |
| متوسط جميع الفواصل النسبية بين قمتين متتالين من موجات R   | MEAN_REL_RR    |
| وسيط جميع الفواصل النسبية بين قمتين متتالين من موجات R  | MEDIAN_REL_RR  |
| الانحراف المعياري لجميع الفواصل النسبية بين قمتين متتالين من موجات R                                | SDRR_REL_RR    |
| الجذر التربيعي لمتوسط مجموع مربعات الفرق بين الفواصل النسبية المتجاورة بين قمتين متتالين من موجات R | RMSSD_REL_RR   |
| الانحراف المعياري لجميع فواصل فروق الفواصل النسبية المتجاورة بين قمتين متتالين من موجات R           | SDSD_REL_RR    |
| نسبة SDRR_REL إلى RMSSD_REL   | SDRR_RMSSD_REL |
| تفرطح جميع الفواصل النسبية بين قمتين متتالين من موجات R   | KURT_REL_RR    |
| التواء جميع الفواصل النسبية بين قمتين متتالين من موجات R  | SKEW_REL_RR    |
| نطاق التردد المنخفض جداً (٠,٠٠٣ هرتز - ٠,٠٤ هرتز) من طيف طاقة HRV                                   | VLF            |
| نطاق التردد المنخفض (٠,٠٤ هرتز - ٠,١٥ هرتز) من طيف طاقة HRV   | LF             |
| نطاق التردد العالي (٠,١٥ هرتز - ٠,٤ هرتز) من طيف طاقة HRV   | HF             |
| إجمالي طيف طاقة HRV   | TP             |
| نسبة LF إلى HF  | LF/HF          |
| نسبة HF إلى LF  | HF/LF          |
| إنتروبيا العينة للفواصل بين قمتين متتالين من موجات R  | sampen         |
| البعد الكسري لهيغوتشي (Higuchi Fractal Dimension)   | higuci         |

## 6. المعالجة الأولية للبيانات:

تم التعامل مع مشكلة كشف التوتر بوصفها مسألة تصنيف متعددة الفئات، حيث تم تمثيل حالات التوتر المختلفة باستخدام ترميز رقمي مناسب (Label Encoding) للمتغير الهدف. يتيح هذا التمثيل توافق البيانات مع خوارزميات التعلم المعتمد على الأشجار، دون التأثير على المعنى الدلالي للفئات.

ونظراً لكون مجموعة البيانات متاحة بتقسيم مسبق إلى مجموعتي تدريب (Train set) واختبار (Test set)، فقد تم اعتماد هذا التقسيم وجرى تقسيم مجموعة التدريب بنسبة ٩٠% لتدريب النموذج و١٠% لبيانات للتحقق (Validation) لاستخدامها في ضبط معاملات النموذج ومنع فرط التكيف. وتم الاحتفاظ بمجموعة الاختبار كاملةً للتقييم النهائي، بما يضمن قياس أداء النموذج على بيانات غير مرئية أثناء التدريب واختبار قدرته على التعميم.

تم اختيار نموذج XGBoost بوصفه النموذج الأساسي في هذه الدراسة، نظراً لملاءمته العالية لطبيعة البيانات المستخدمة إذ يتميز هذا النموذج بقدرته على نمذجة العلاقات غير الخطية المعقدة بين المؤشرات الحيوية والتعامل مع التداخل والاعتماد المتبادل بين الخصائص الفيزيولوجية وتحقيق أداء مستقر في وجود ضجيج أو عدم توازن نسبي في البيانات. تُعد هذه الخصائص جوهرية في تطبيقات كشف التوتر، حيث غالباً ما تتداخل الإشارات الفيزيولوجية ولا تتبع أنماطاً خطية بسيطة.

## 7. معايير تقييم الأداء:

تم تقييم أداء النموذج باستخدام مجموعة من المقاييس المعيارية المستخدمة في أنظمة التصنيف الطبي، شملت: مصفوفة الارتباك (Confusion Matrix) لتحليل أنماط الأخطاء بين فئات التوتر المختلفة، منحى

ROC-AUC لقياس قدرة النموذج على التمييز بين الفئات، ومنحنى Precision-Recall الذي يُعد أكثر ملاءمة في حالة وجود عدم توازن نسبي بين الفئات. يوفر هذا التقييم المتعدد الأبعاد فهماً شاملاً لجودة النموذج من حيث الدقة والموثوقية.

لضمان شفافية النموذج وقابليته للاستخدام في السياقات الصحية تم توظيف تقنيات XAI باستخدام SHAP الذي أتاح إمكانية تحليل المساهمة الفردية لكل ميزة في قرارات النموذج وتحديد المؤشرات الفيزيولوجية الأكثر تأثيراً في كشف التوتر، ودعم موثوقية النموذج من خلال تفسير سلوكه بما يتماشى مع المعرفة الفيزيولوجية حيث تسهم هذه الخطوة في تعزيز قابلية تفسير النموذج وشفافيته، كما تدعم اعتماده كنظام دعم قرار ذكي قائم على أسس تفسيرية واضحة، بدلاً من كونه مجرد أداة تصنيف تعمل وفق آلية صندوقية مغلقة.

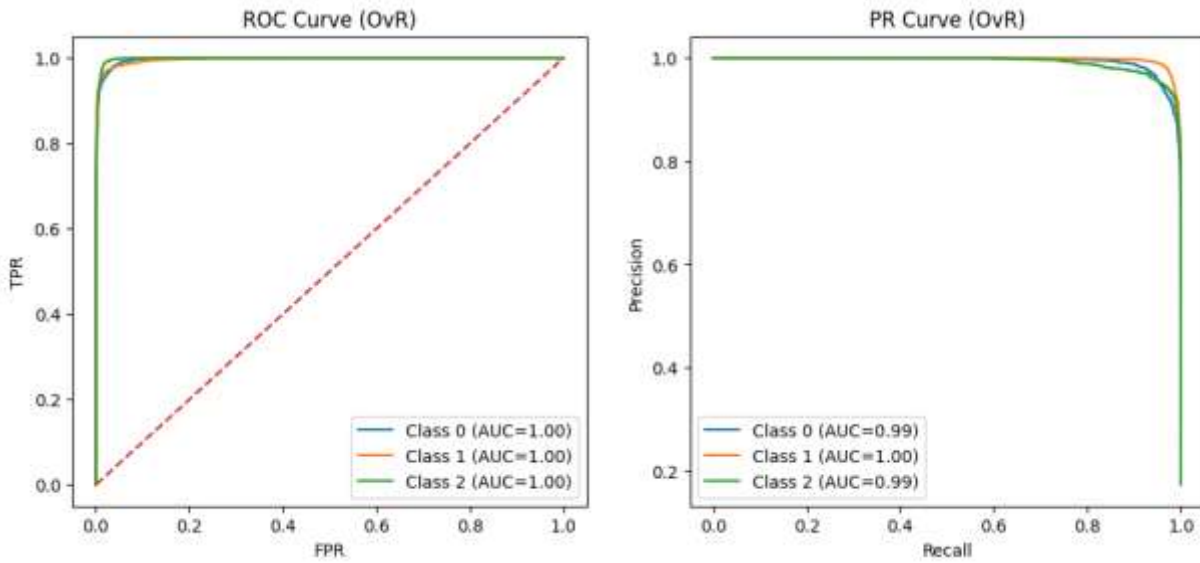
## 8. النتائج والمناقشة:

### 8.1 أداء التصنيف:

تم تقييم الأداء التنبؤي لنموذج XGBoost باستخدام تقرير تصنيف مفصل، شمل مقاييس الدقة (Precision) والتذكر (Recall) ومقياس F1 لكل فئة من فئات الإجهاد الثلاث، إضافةً إلى المقاييس الكلية. أظهرت النتائج أن النموذج حقق أداءً مرتفعاً ومتوازناً عبر جميع الفئات، فقد سجلت فئة المقاطعة (Interruption) دقة مقدارها ٠,٩٨ وتذكر بلغ ٠,٩١، مع درجة  $F1 = 0.95$ ، مما يشير إلى قدرة عالية على التعرف الصحيح على هذه الحالة مع معدل منخفض من الإيجابيات الخاطئة (False Positive). أما فئة عدم وجود إجهاد (No Stress)، فقد حققت أعلى أداءً عالياً من حيث التذكر بقيمة ٠,٩٩، إلى جانب دقة مقدارها ٠,٩٣ ودرجة  $F1 = 0.96$ ، وهو ما يعكس قدرة النموذج على التقاط الأنماط الفيزيولوجية للحالة الطبيعية بشكل شبه كامل. وأخيراً سجلت فئة ضغط الوقت (Time Pressure) دقة مقدارها ٠,٩٦ وتذكراً بلغ ٠,٩٠، مع درجة  $F1 = 0.93$ ، مما يدل على تمييز فعال لهذه الحالة رغم التداخل الجزئي في خصائصها الفيزيولوجية مع الفئات الأخرى. وعلى المستوى الكلي، بلغت الدقة العامة (Accuracy) للنموذج ٠,٩٥، مما يؤكد اتزان الأداء واستقراره عند مراعاة التوزيع الحقيقي للعينات.

ولتعزيز هذا التقييم القائم على المقاييس النقطية، تم تحليل أداء النموذج باستخدام منحنيات ROC والدقة-التذكر (PR) في إعداد متعدد الفئات بأسلوب One-vs-Rest (OvR)، كما هو موضح في الشكل (٣). أظهرت منحنيات ROC أن النموذج يحقق فصلاً شبه مثالي بين الفئات، حيث بلغت قيم  $AUC-ROC = 1.00$  لجميع الفئات الثلاث، مما يدل على قدرة ممتازة على التمييز بين حالات الإجهاد المختلفة بغض النظر عن عتبة القرار المختارة.

وبالمثل، أظهرت منحنيات PR أداءً قوياً، حيث بلغت قيم AUC-PR نحو ٠,٩٩ لفئتي المقاطعة وضغط الوقت، و١,٠٠ لفئة عدم وجود إجهاد. وتعكس هذه القيم قدرة النموذج على الحفاظ على مستويات دقة مرتفعة حتى عند معدلات تذكّر عالية، وهو أمر بالغ الأهمية في تطبيقات الكشف عن الإجهاد، حيث قد يؤدي ارتفاع الإيجابيات الخاطئة أو السلبيات الخاطئة إلى قرارات غير موثوقة في البيئات الواقعية.

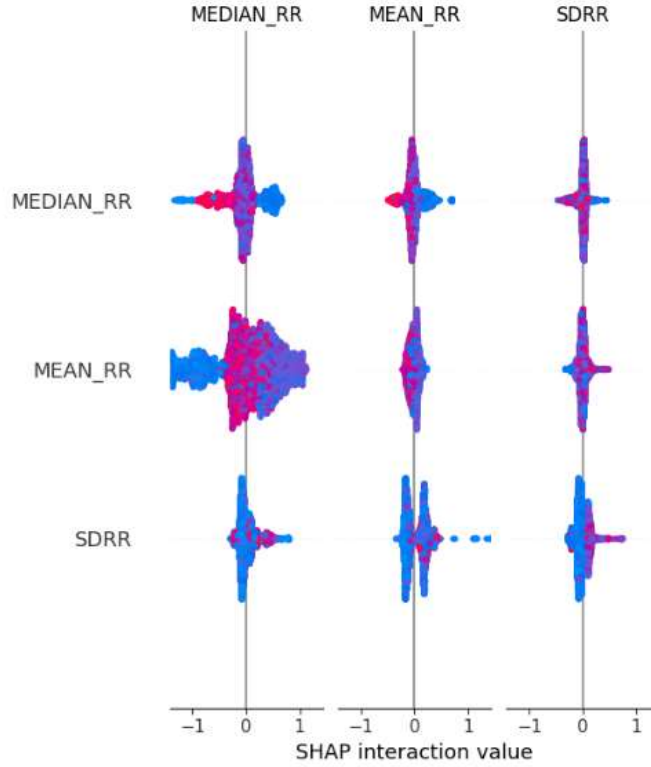


الشكل (٣): منحنيات ROC والدقة-التذكر (PR) للنموذج.

تشير هذه النتائج مجتمعة إلى أن نموذج XGBoost لا يحقق فقط دقة تصنيف عالية، بل يتمتع أيضاً بقدرة قوية ومستقرة على الفصل بين الحالات المعرفية المختلفة عبر نطاق واسع من عتبات القرار، مما يعزز ملاءمته للاستخدام العملي في أنظمة الكشف عن الإجهاد المعتمدة على خصائص تقلب معدل ضربات القلب .HRV

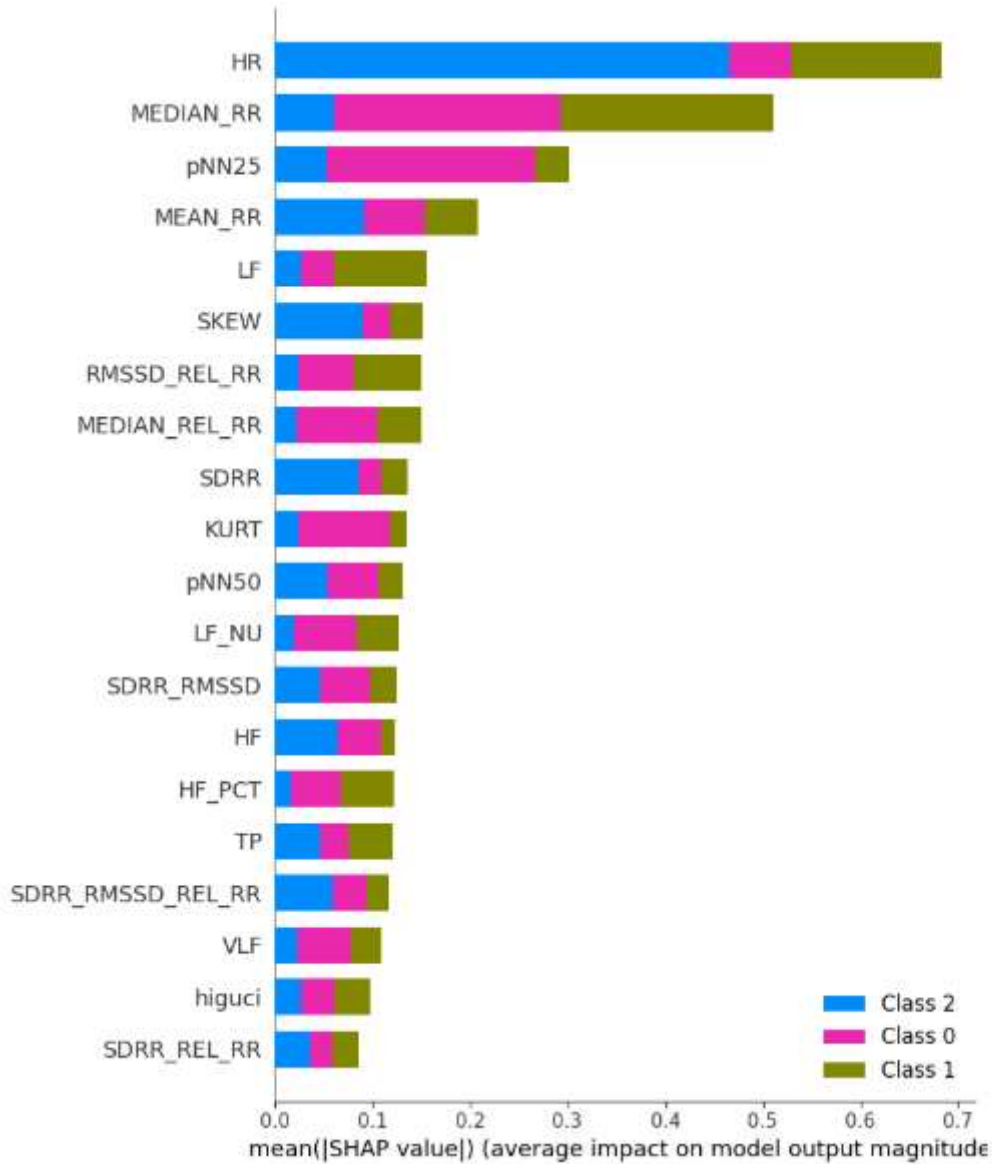
## 8.2 قابلية تفسير النموذج باستخدام SHAP

يوضح الشكل (٤) مخطط ملخص تفاعلات SHAP بين أهم خصائص تقلب معدل ضربات القلب MEDIAN\_RR و MEAN\_RR و SDRR، مبيّناً التأثير المشترك لهذه الخصائص على تنبؤات نموذج XGBoost. تمثل قيم SHAP الموجبة مساهمة التفاعل في تعزيز احتمال التنبؤ بحالات الإجهاد، في حين تشير القيم السالبة إلى تقليل هذا الاحتمال. تُظهر النتائج أن النموذج يلتقط تفاعلات غير خطية ذات دلالة فيزيولوجية، حيث يسهم الانخفاض المتزامن في فترات RR ومستوى التباين (SDRR) في دفع التنبؤ نحو حالات الإجهاد، بما يتوافق مع الاستجابات المعروفة للجهاز العصبي اللاإرادي تحت الحمل المعرفي.



الشكل (٤): مخطط ملخص تفاعلات SHAP بين أهم خصائص HRV.

يوضح الشكل (٥) مخطط (bar plot) SHAP summary الذي يبين الأهمية النسبية للميزات المستخدمة في النموذج التنبؤي متعدد الفئات. يمثل المحور الأفقي متوسط القيمة المطلقة لقيم SHAP، والذي يعكس متوسط مقدار تأثير كل ميزة على مخرجات النموذج، بينما تُرتب الميزات على المحور الرأسي تنازلياً حسب أهميتها. تُظهر الألوان مساهمة كل ميزة في التنبؤ بكل فئة على حدة. تشير النتائج إلى أن معدل ضربات القلب (HR) هو الميزة الأكثر تأثيراً في قرارات النموذج، يليه MEDIAN\_RR، ثم مقاييس تقلب معدل ضربات القلب المعتمدة على الزمن مثل pNN25 و MEAN\_RR. في المقابل، كان تأثير المقاييس المعتمدة على التردد (مثل LF و HF و VLF) والمقاييس الإحصائية الأعلى رتبة (مثل SKEW و KURT) أقل نسبياً. تعكس هذه النتائج اعتماد النموذج بشكل رئيسي على الخصائص الزمنية لتقلب معدل ضربات القلب، وهو ما يتوافق مع الأساس الفسيولوجي لتأثير التوتر على ديناميكيات القلب.

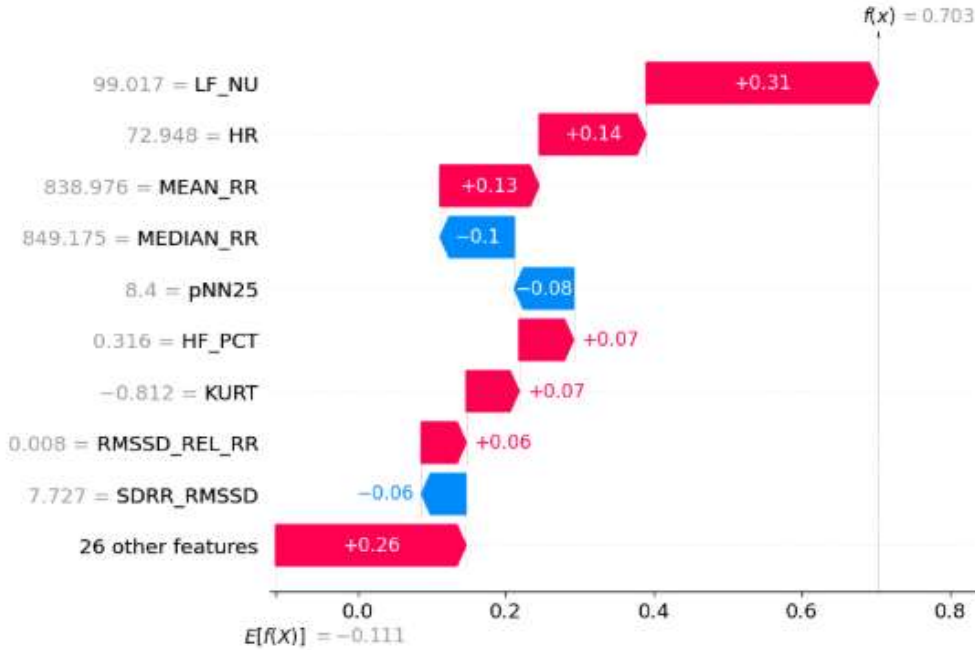


الشكل (٥): الأهمية النسبية للميزات المستخدمة في النموذج التنبؤي.

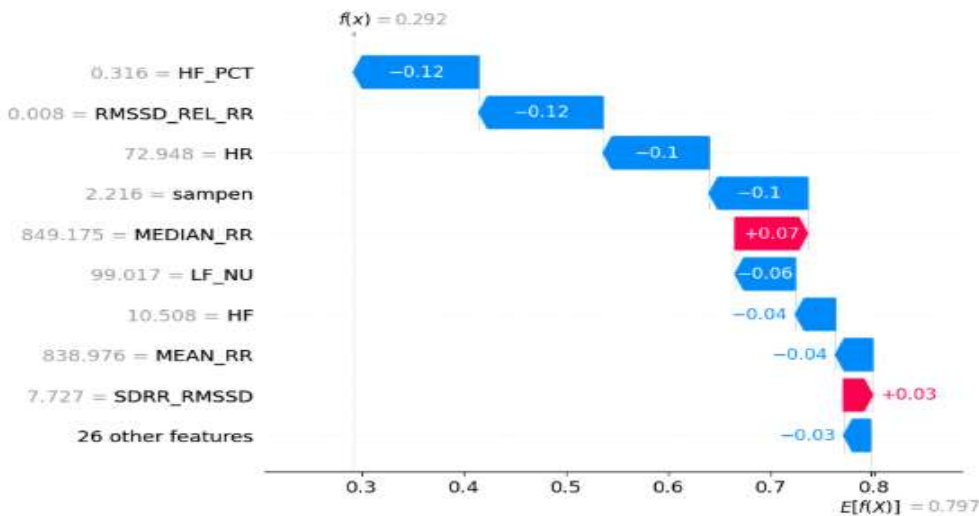
يوضح الشكل (٦) مخطط SHAP Waterfall الذي يفسر قرار النموذج لعينة فردية محددة من الصنف (Interruption)، من خلال بيان كيفية مساهمة الميزات المختلفة في الانتقال من القيمة الأساسية للنموذج  $E[f(X)]$  إلى قيمة التنبؤ النهائية  $f(x)$ . تبدأ العملية من القيمة المتوقعة للنموذج  $E[f(X)] = -0.111$ ، والتي تمثل متوسط مخرجات النموذج عبر جميع العينات، ثم تُضاف مساهمات الميزات واحدة تلو الأخرى. تمثل الأشرطة الحمراء الميزات التي تزيد من قيمة التنبؤ، بينما تمثل الأشرطة الزرقاء الميزات التي تخفّضها، مع كون طول الشريط معبراً عن مقدار التأثير.

تُظهر النتائج أن الميزة LF\_NU كانت الأكثر تأثيراً إيجابياً على التنبؤ، تليها HR و HF\_PCT، مما أدى إلى رفع ناتج النموذج. في المقابل، ساهمت ميزات مثل MEDIAN\_RR و MEAN\_RR و pNN25 و SDRR\_RMSSD في خفض قيمة التنبؤ. كما يظهر أن مجموعة الميزات الأخرى (٢٦ ميزة إضافية) كان لها تأثير تراكمي ملحوظ. في النهاية، أدت هذه المساهمات مجتمعة إلى الوصول إلى قيمة تنبؤ نهائية مقدارها

نموذج تعلم آلة قابل للتفسير للكشف عن التوتر النفسي  
 f(x)=0.703 مما يوضح كيفية اعتماد النموذج على تفاعل ميزات تقلب معدل ضربات القلب المختلفة لاتخاذ قراره على مستوى العينة الفردية.

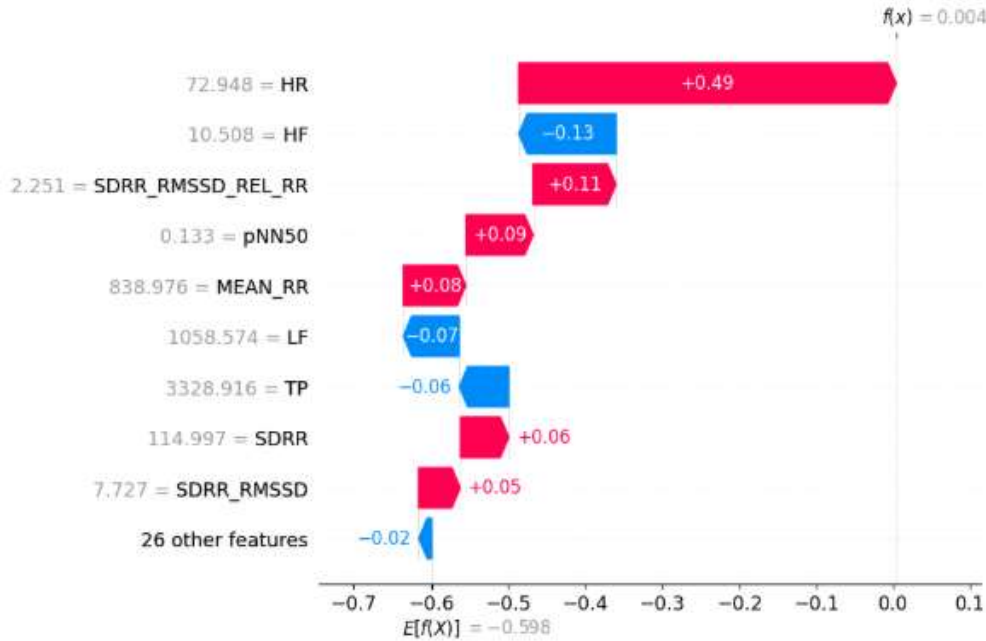


الشكل (٦): مخطط SHAP Waterfall الذي يفسر قرار النموذج لعينة فردية محددة من الصنف (Interruption).  
 يوضح الشكل (٧) مخطط SHAP Waterfall الذي يفسر ناتج النموذج لعينة فردية محددة من الصنف (no stress)، تتطرق عملية التفسير من القيمة المتوقعة للنموذج  $E[f(X)] = 0.797$ ، والتي تمثل متوسط مخرجات النموذج عبر جميع العينات. تُظهر النتائج أن ميزات HF\_PCT و RMSSD\_REL\_RR و HR و sampen كان لها التأثير الأكبر في خفض ناتج النموذج، مما أدى إلى تقليل احتمال الانتماء إلى هذه الفئة. في المقابل، ساهمت ميزات مثل MEDIAN\_RR و SDRR\_RMSSD في رفع قيمة التنبؤ، وإن كان تأثيرها أقل نسبياً. كما أن مجموعة الميزات الأخرى (٢٦ ميزة إضافية) أظهرت تأثيراً تراكمياً محدوداً. في المحصلة النهائية، أدت هذه المساهمات المتعارضة إلى الوصول إلى قيمة تنبؤ مقدارها  $f(x) = 0.292$ .



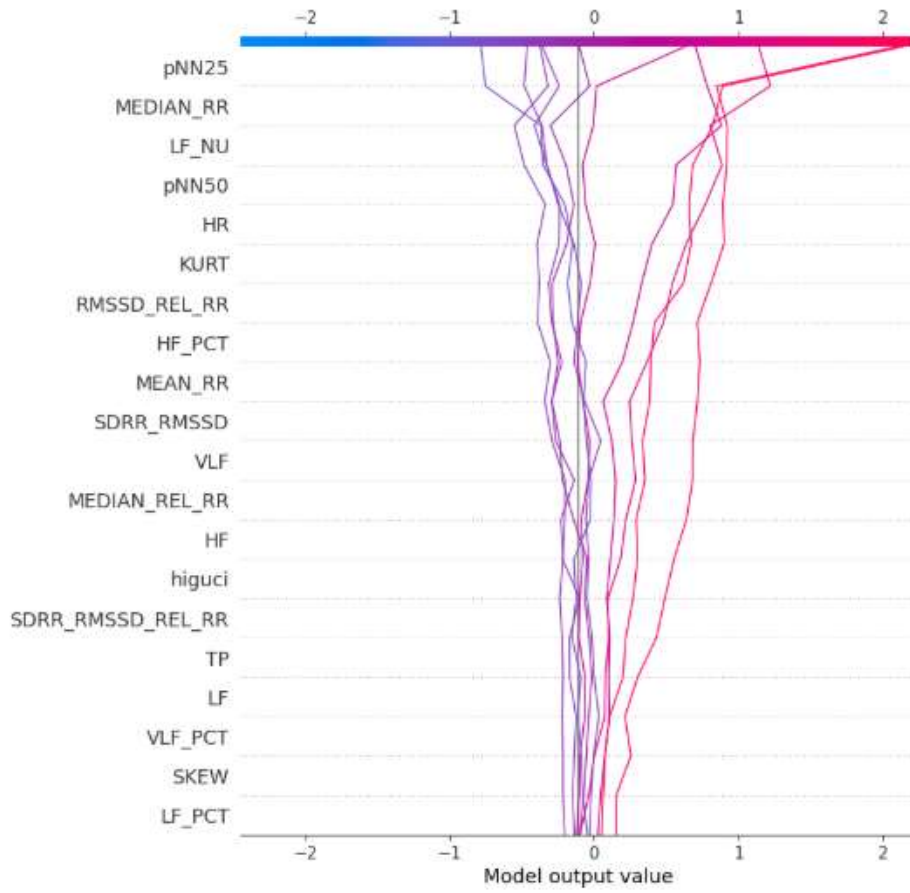
الشكل (٧): مخطط SHAP Waterfall الذي يفسر قرار النموذج لعينة فردية محددة من الصنف (no stress).

أخيراً يعرض الشكل (٨) مخطط SHAP Waterfall الذي يفسر مخرجات النموذج لعينة فردية محددة من الصنف (time pressure)، تبدأ عملية التفسير من القيمة المتوقعة للنموذج  $E[f(X)] = -0.598$ ، والتي تمثل متوسط مخرجات النموذج عبر جميع العينات. تُظهر النتائج أن معدل ضربات القلب (HR) كان العامل الأكثر تأثيراً إيجابياً، حيث ساهم بزيادة كبيرة في ناتج النموذج، تليه ميزات مرتبطة بتقلب معدل ضربات القلب مثل SDRR\_RMSSD\_REL\_RR و pNN50 و MEAN\_RR. في المقابل، أسهمت ميزات المجال الترددي مثل HF و LF و TP في خفض قيمة التنبؤ. كما كان للتأثير التراكمي لبقية الميزات (٢٦ ميزة إضافية) دور محدود نسبياً. في النهاية، أدت هذه المساهمات المتعاكسة إلى الوصول إلى قيمة تنبؤ نهائية مقدارها  $f(x) = 0.004$ .



الشكل (٨): مخطط SHAP Waterfall الذي يفسر قرار النموذج لعينة فردية محددة من الصنف (time pressure).

يمكن أيضاً استخدام مخططات SHAP Decision Plot لتفسير قرارات النموذج، حيث تعرض هذه المخططات مسار اتخاذ القرار للنموذج. يظهر الشكل (٩) مخطط Decision Plot لأول ١٠ عينات من البيانات بالنسبة للفئة (interruption)، موضحاً كيفية تراكم مساهمات الميزات المختلفة بدءاً من القيمة الأساسية للنموذج وصولاً إلى ناتج التنبؤ النهائي لكل عينة. يمثل المحور الأفقي القيم التراكمية لـ SHAP values، حيث تشير القيم الموجبة (باللون الأحمر) إلى الميزات التي تدفع التنبؤ نحو زيادة احتمال الانتماء إلى الفئة، بينما تشير القيم السالبة (باللون الأزرق/البنفسجي) إلى الميزات التي تقلل هذا الاحتمال. أما المحور الرأسي فيعرض الميزات مرتبة حسب أهميتها في المسار التفسيري. كما يعكس تقارب أو تباعد المسارات درجة التشابه أو التباين في السلوك التنبؤي بين العينات. بشكل عام، يبرز هذا المخطط الطبيعة التراكمية لتأثير الميزات، ويوضح أن قرار النموذج لا يعتمد على ميزة واحدة فقط، بل على تفاعل متسلسل بين عدة خصائص لتقلب معدل ضربات القلب، مما يعزز فهم ديناميكية القرار وشفافية النموذج على مستوى العينات المتعددة.



الشكل (٩): مخطط SHAP Decision Plot لأول ١٠ عينات من البيانات بالنسبة للفئة (interruption).

يوضح الجدول (٢) مقارنة شاملة بين الدراسة الحالية وعدد من الدراسات الحديثة التي استخدمت مجموعة البيانات SWELL-KW نفسها. تُظهر الدراسة الحالية أداءً تنافسياً مرتفعاً باستخدام نموذج XGBoost حيث حقق دقة بلغت ٩٥% مع قيم شبه مثالية لكل من منحنيات ROC والدقة-التنكر (PR)، وعلى عكس الدراسات الأخرى التي عملت على مجموعة البيانات هذه، تميزت الدراسة الحالية بدمج تقنيات الذكاء الاصطناعي القابل للتفسير باستخدام تقنية SHAP، مما يعزز موثوقية النتائج وقابليتها للتفسير، ويؤكد أن مساهمة الدراسة الحالية لا تقتصر على الأداء فقط، بل تمتد إلى تحقيق توازن مهم بين الدقة العالية وقابلية التفسير، وهو عامل حاسم في التطبيقات الطبية والحيوية الواقعية.

الجدول (٢): مقارنة بين الدراسة الحالية والدراسات التي استخدمت مجموعة البيانات SWELL-KW.

| الدراسة               | مجموعة البيانات              | نوع البيانات | التقنية المستخدمة          | أفضل النتائج        | قابلية التفسير    |
|-----------------------|------------------------------|--------------|----------------------------|---------------------|-------------------|
| Singh et al. (2025)   | SWELL-KW                     | HRV          | RF, SVM, KNN               | 98% Accuracy        | لا                |
| Kizito et al. (2019)  | SWELL-KW + PHRENIC + COMFORT | HRV          | RF                         | 1.0 (100%) Accuracy | لا                |
| Prakash et al. (2025) | SWELL-HRV                    | HRV          | MyWear smart T-shirt + SVM | 99.25% Accuracy     | لا                |
| الدراسة الحالية       | SWELL-KW                     | HRV          | XGBoost                    | 95% Accuracy        | نعم باستخدام SHAP |

## 9. الخاتمة (Conclusion):

قدّمت هذه الدراسة إطاراً متكاملًا وقابلًا للتفسير لكشف حالات التوتر النفسي اعتماداً على خصائص تقلب معدل ضربات القلب (HRV) باستخدام نموذج XGBoost على مجموعة بيانات SWELL-KW. أظهرت النتائج أن النموذج المقترح يحقق أداء تصنيف مرتفع ومتوازن عبر فئات الإجهاد المختلفة، مدعوماً بمقاييس كمية قوية شملت دقة عامة بلغت ٩٥% وقيم AUC-ROC و AUC-PR شبه مثالية، مما يعكس قدرة عالية على التمييز بين الحالات المعرفية تحت ظروف تشغيل متنوعة. إلى جانب الأداء التنبؤي، أسهم دمج تقنيات الذكاء الاصطناعي القابل للتفسير (XAI) باستخدام SHAP في تعزيز شفافية النموذج وفهم آليات اتخاذ القرار داخله. فقد أظهرت تحليلات SHAP أن الخصائص الزمنية لتقلب معدل ضربات القلب لا سيما معدل ضربات القلب HR و MEDIAN\_RR و MEAN\_RR و pNN25 تلعب الدور الأبرز في التنبؤ بحالات التوتر، وهو ما يتوافق مع الأسس الفيزيولوجية المعروفة لتنظيم الجهاز العصبي اللاإرادي تحت الحمل المعرفي. كما بيّنت المخططات المختلفة أن قرارات النموذج لا تعتمد على مؤشرات منفردة، بل على تفاعل غير خطي ومعقد بين مجموعة من الميزات، الأمر الذي يعزز الثقة في النموذج بوصفه أداة دعم قرار وليست مجرد مصنّف صندوق مغلق. تؤكد هذه النتائج أن الجمع بين نماذج تعلم الآلة القوية وأساليب التفسير المتقدمة يمثل اتجاهاً واعداً لتطوير أنظمة كشف توتر موثوقة وقابلة للاعتماد في البيئات الواقعية، لا سيما في سياقات العمل الذكي والصحة الرقمية. وعلى الرغم من القيود المرتبطة بالاعتماد على مجموعة بيانات واحدة، فإن الإطار المقترح يضع أساساً منهجياً متيناً يمكن البناء عليه مستقبلاً عبر التحقق متعدد المجموعات، والنمذجة الزمنية لديناميكيات الإجهاد، ودمج مصادر بيانات إضافية. وبذلك، تسهم هذه الدراسة في سد الفجوة بين الدقة التنبؤية وقابلية التفسير، وتقدّم خطوة عملية نحو أنظمة كشف إجهاد أكثر شفافية وموثوقية وقابلية للتطبيق.

## 10. التوصيات:

رغم النتائج الواعدة التي قدمتها هذه الدراسة إلى أنها تظل محدودة بسبب الاعتماد على مجموعة بيانات واحدة فقط وفي بيئة تجريبية مضبوطة. لذلك يوصى بالعمل على التحقق من صحة النتائج عبر مجموعات بيانات متعددة، ودراسة النمذجة الزمنية لديناميكيات الإجهاد، واستكشاف أساليب هجينة تجمع بين الإشارات الفيزيولوجية والسلوكية. كما قد يسهم توسيع تحليل قابلية التفسير ليشمل أنماط الإجهاد الطويلة في تعزيز قابلية التطبيق في البيئات الواقعية.

## المراجع:

1. Abdel-Latif, M. M., Rashid, M., Askari, M. R., Shahidehpour, A., et al. 2024. Acute Psychological Stress Detection Using Explainable Artificial Intelligence for Automated Insulin Delivery. *Signals*, 5(3), 494–507.
2. Chintalapati, A., Annamalai, R., Enkhat, K., Ozaydin, F., & Sivashanmugam, K. 2024. Enhancing Stress Identification Using Machine Learning: Revealing Key Factors with SHAP-Driven Explainable AI.
3. Gedam, S., Dutta, S., & Jha, R. 2025. Analyzing mental stress in Indian students through advanced machine learning and wearable technologies. *Scientific Reports*, 15(1), 20610.
4. Nguyen, M. N., Le-Duc, K., Pham, T. H., Nguyen, T., et al. 2025. A Wearable Device Dataset for Mental Health Assessment Using Laser Doppler Flowmetry and Fluorescence Spectroscopy Sensors. *arXiv preprint arXiv:2502.00973*.
5. Shahriar, K. A. 2025. Why Nonlinear Models Matter: Unified Analysis of Cognitive Load, Stress, and Exercise Using Wearable Physiological Signals. *arXiv preprint arXiv:2512.06099*.
6. Singh, R., Ranjan, V., Ganguly, A., & Halder, S. 2025. Stress Classification Using Heart Rate Variability and Machine Learning Models. *Procedia Computer Science*, 258, 4248–4256.
7. Nkurikiyeyezu, K., Shoji, K., Yokokubo, A., & Lopez, G. 2019. Thermal Comfort and Stress Recognition in Office Environment. *Proceedings of the 6th International Conference on Physiological Computing Systems (PHYCS)*, 63-71.
8. Neigel, P., Vargo, A., Tag, B., & Kise, K. 2025. Unobtrusive stress detection using wearables: application and challenges in a university setting. *Frontiers in Computer Science*, 7, 1575404.
9. Prakash, K., Harshitha, M. N., Lakshmi, G. N., Moses, P., et al. 2025. MyWear revolutionizes real-time health monitoring with comparative analysis of machine learning. *Scientific Reports*, 15(1), 1860.
10. Moser, M. K., Ehrhart, M., & Resch, B. 2024. An Explainable Deep Learning Approach for Stress Detection in Wearable Sensor Measurements. *Sensors*, 24(16), 5085.