

Studying the Relationship Between Arabic Handwriting and Personality Traits Using Artificial Intelligence Techniques

Batool Khaddour* 
Dr. Khaldoun Fake**
Dr. Majed Ali ***

(Received 6 / 4 / 2026. Accepted 17 / 6 / 2026)

□ ABSTRACT □

This study aims to develop an intelligent system for personality analysis based on Arabic handwriting characteristics, following the Five Factor Model (FFM), using artificial intelligence and deep learning techniques. A dataset of 500 participants was constructed, from which both handcrafted features and deep features were extracted using pre-trained models such as VGG16 and DenseNet201 to evaluate their impact on classification performance. A Random Forest classifier was adopted as the primary model and optimized using GridSearchCV, with a separate model trained for each personality trait. Due to data imbalance, the SMOTE technique was applied to balance the dataset and improve model generalization. Experiments were conducted under two scenarios: original data and balanced data.

The results demonstrate the superiority of deep features, DenseNet201 (DNS), and their combination with handcrafted features, achieving an F1-score of up to 76% and an accuracy of 81 % when using SMOTE. These findings highlight the importance of feature representation and data balancing techniques in improving classification performance.

Keywords: Personality Analysis, Handwriting Analysis, Deep Learning, Random Forest, Big Five Personality Traits.

Copyright  :Latakia University journal (formerly Tishreen) -Syria, The authors retain the copyright under a CC BY-NC-SA 04

* Master's Student- Department of Computer Engineering and Automatic Control -Faculty of Mechanical and Electrical Engineering - Latakia University (formerly Tishreen) - Latakia - Syria.
battoul.khaddoor@tishreen.edu.sy

** Assistant Professor - Department of Computer and Automatic Control Engineering - Faculty of Mechanical and Electrical Engineering - Latakia University (formerly Tishreen) - Latakia - Syria.
khaldoon.fake@tishreen.edu.sy

***Assistant Professor - Department of Artificial Intelligence - Faculty of Information Engineering- Latakia University (formerly Tishreen) - Latakia - Syria.

دراسة العلاقة بين الكتابة اليدوية باللغة العربية وصفات الشخصية باستخدام تقنيات الذكاء الصناعي

بتول خضور* 

د. خلدون فاقي**

د. مجد علي***

(تاريخ الإيداع 6 / 4 / 2026. قُبِلَ للنشر في 17 / 6 / 2026)

□ ملخص □

تهدف هذه الدراسة إلى تطوير نظام ذكي لتحليل الشخصية اعتماداً على خصائص الخط اليدوي العربي وفق نموذج العوامل الخمسة الكبرى (Five Factor Model - FFM)، باستخدام تقنيات الذكاء الاصطناعي والتعلم العميق. تم بناء قاعدة بيانات مكونة من 500 مشارك، حيث جرى استخراج ميزات يدوية (Handcrafted Features) وميزات عميقة باستخدام نماذج مدربة مسبقاً مثل VGG16 وDenseNet201، بهدف دراسة تأثيرها على أداء نماذج التصنيف. تم اعتماد خوارزمية الغابة العشوائية (Random Forest) كنموذج تصنيف رئيسي بعد تحسينها باستخدام Grid Search، مع تدريب نموذج مستقل لكل صفة. ونظراً لعدم توازن البيانات، تم تطبيق تقنية SMOTE لإعادة توازن الفئات وتحسين قدرة النماذج على التعميم، حيث أُجريت التجارب على البيانات الأصلية وبعد التوازن. أظهرت النتائج تفوق الميزات العميقة، خاصة DenseNet201، إضافة إلى دمجها مع الميزات اليدوية، حيث وصلت قيمة F1-Score إلى (76%)، والصحة إلى (81%) عند استخدام SMOTE. كما بيّنت النتائج أهمية اختيار تمثيل البيانات المناسب إلى جانب تقنيات المعالجة المسبقة. تؤكد هذه الدراسة فعالية استخدام التعلم العميق في تحليل الشخصية من الخط اليدوي العربي، مع إمكانيات تطبيق واسعة في مجالات متعددة.

الكلمات المفتاحية: تحليل الشخصية، تحليل الخط اليدوي، الغابة العشوائية، التعلم العميق، صفات الشخصية الخمسة الكبرى.

حقوق النشر  : مجلة جامعة اللاذقية (تشرين سابقاً) - سورية، يحتفظ المؤلفون بحقوق النشر بموجب الترخيص CC BY-NC-SA 04

* طالبة ماجستير - قسم هندسة الحاسبات والتحكم الآلي - كلية الهندسة الميكانيكية والكهربائية - جامعة اللاذقية (تشرين سابقاً) - اللاذقية - سورية. battoul.khaddoor@tishreen.edu.sy
** مدرس - قسم هندسة الحاسبات والتحكم الآلي - كلية الهندسة الميكانيكية والكهربائية - جامعة اللاذقية (تشرين سابقاً) - اللاذقية - سورية. khaldoon.fake@tishreen.edu.sy
*** مدرس - قسم الذكاء الصناعي - كلية الهندسة المعلوماتية - جامعة اللاذقية (تشرين سابقاً) - اللاذقية - سورية.

مقدمة:

يُعد تحليل الشخصية من المواضيع ذات الأهمية المتزايدة في مجالات علم النفس، والموارد البشرية، والتفاعل الإنساني-الآلي. وضمن النماذج النفسية الأكثر اعتماداً في توصيف الشخصية، يبرز نموذج العوامل الخمسة الكبرى (Five Factor Model)، والذي يقسم الشخصية إلى خمس صفات رئيسية: الاجتماعية (Extraversion)، الود (Agreeableness)، الضمير الحي (Conscientiousness)، العصبية (Neuroticism)، والانفتاح على التجارب (Openness). ومع التطور التقني في مجال الذكاء الصناعي ومعالجة الصور، ظهرت اتجاهات بحثية حديثة تستهدف تحليل المظاهر السلوكية والفسيولوجية للكشف عن الصفات الشخصية، ومنها تحليل الكتابة اليدوية باعتبارها مرآة غير مباشرة للتكوين النفسي والسلوكي للفرد. وقد أظهرت دراسات عديدة أن خصائص الكتابة اليدوية كالضغط، الميل، التباعد، وغير ذلك، تحمل مؤشرات قابلة للتحليل يمكن توظيفها في بناء نماذج ذكية لتصنيف الشخصية.

في هذا السياق، يهدف هذا البحث إلى دراسة إمكانية استخدام صور الكتابة اليدوية العربية كنقطة انطلاق لاستخلاص صفات الشخصية الخمس، من خلال تطوير نموذج تصنيفي يعتمد على مجموعة من الميزات المُستخرجة يدوياً، وكذلك ميزات عميقة مُستخرجة باستخدام نماذج التعلم العميق المدربة مسبقاً (DenseNet201, VGG16). ولتحقيق أداء عالٍ، تم اعتماد خوارزمية التصنيف Random Forest، مع تحسين أدائها عبر Grid Search لضبط المعاملات المثلى.

نظراً لطبيعة البيانات المعتمدة، والتي تم جمعها عن طريق استبيان نفسي، فقد واجه البحث مشكلة توازن غير متكافئ بين صفوف البيانات، وهو ما قد يؤثر سلباً على دقة النماذج. وللتغلب على هذه المشكلة، تم اعتماد تقنية SMOTE (Synthetic Minority Over-sampling Technique) لتوليد عينات اصطناعية وإعادة توازن البيانات بهدف تحسين قدرة النماذج على التعميم ورفع دقة التصنيف.

أهمية البحث وأهدافه:

تهدف هذه الدراسة إلى فحص مدى صلاحية تحليل الخط اليدوي كأداة لتقييم الشخصية، وذلك من خلال تقييم العلاقة بين نتائج اختبار نفسي موثوق يُعرف باسم اختبار مؤشرات العوامل الخمسة الكبرى، وهو اختبار يعتمد على تقارير الأفراد الذاتية لقياس خمس صفات شخصية رئيسية، وهي: الاجتماعية (Extraversion)، الود (Agreeableness)، الضمير الحي (Conscientiousness)، العصبية (Neuroticism)، والانفتاح على التجارب (Openness) اعتماداً على مقياس (IPIP-BFFM) المعتمد عالمياً.

حيث تكمن أهمية هذا البحث من الحاجة إلى تطوير أدوات ذكية قادرة على فهم الأبعاد النفسية للأفراد من خلال تحليل الكتابة اليدوية باللغة العربية، بوصفها وسيلة تعبير شخصية تحمل في طياتها مؤشرات سلوكية ونفسية عميقة. في ظل التقدم المتسارع في تقنيات الذكاء الصناعي، أصبحت خوارزميات التصنيف مثل الغابة العشوائية (Random Forest) ونماذج التعلم العميق مثل الشبكات العصبونية التلافيفية (CNN) أدوات واعدة لتحليل الأنماط المعقدة في البيانات البصرية. يستند هذا البحث إلى بناء نموذج ذكي يهدف إلى تصنيف خمس صفات رئيسية للشخصية (وفق نموذج العوامل الخمسة الكبرى) من خلال استخراج خصائص دقيقة من صور الكتابة

اليديوية العربية، سواء باستخدام ميزات مستخرجة يدوياً أو عبر نماذج عميقة مثل (DenseNet201, VGG16). ويعتمد البحث أيضاً على تقنيات زيادة البيانات وإعادة التوازن باستخدام تقنية SMOTE، من أجل تحسين أداء النماذج وتحقيق دقة أعلى في التصنيف. وبهذا يسهم البحث في تعزيز التكامل بين الذكاء الصناعي والتحليل النفسي في بيئة لغوية وثقافية ما تزال الدراسات فيها محدودة، مما يفتح آفاقاً جديدة في مجالات مثل التوظيف، والتعليم، وتقييم الشخصية بشكل غير تداخلي وفعال.

طرائق البحث ومواده:

1. الدراسات السابقة

تناولت الأبحاث الأكاديمية تحليل الشخصية عبر خط اليد من خلال منهجيات متعددة، حيث قدم Hashemi وآخرون (2015) دراسة رائدة على الخط الفارسي [1]، استخلصوا من خلالها تسع ميزات دقيقة من خط اليد (مثل هوامش الصفحة، وكثافة النص، وسرعة الكتابة) باستخدام مصنف SVM وعلى الرغم من نجاح الدراسة في إثبات قدرة النظام على محاكاة تقييمات الخبراء البشريين وتحقيق نتائج وصفية واعدة، إلا أنها لم تقدم قياسات كمية دقيقة، مما يجعل من الصعب تقييم مدى كفاءة النموذج إحصائياً عند مقارنته بأنظمة أخرى. في السياق نفسه، استخدم B Fallah وآخرون في العام (2016) خصائص الكتابة اليدوية للتنبؤ بالشخصية [2]، حيث أجريت التجارب باستخدام مجموعة بيانات (MMPI)¹. تم استخراج ميزات مستقلة من النص مثل الهوامش، أحجام الأحرف، مسافات الأسطر والكلمات، ميل الكلمات، والنسبة الرأسية للأحرف، ثم تم تدريب شبكة عصبونية لتصنيف الصفات وفقاً لدرجة مقياس MMPI. بلغ معدل الدقة حوالي 70%، لكن الدراسة بينت أن مقياس MMPI محدود وقديم لتقييم الشخصية، إضافة إلى اعتمادها على ميزات يدوية فقط دون الاستفادة من تمثيلات عميقة. لاحقاً، في عام 2017، اقترح Mihai Gavrilescu نموذجاً ثلاثي الطبقات يجمع بين الشبكات العصبونية و آلة الأشعة الداعمة (Support Vector Machine) SVM لتحديد نوع الشخصية وفق مؤشر Myers-Briggs بناءً على تحليل خصائص الكتابة اليدوية [3]. شملت الميزات المستخدمة: خط الأساس، ضغط القلم، ميل الكلمات، خطوط الربط، بالإضافة إلى شكل الحرفين "t" و "f". حقق النموذج دقة عالية بلغت 89.2%، إلا أن محدودية حجم العينة (64 مشاركاً) أثّرت على تعميم النتائج، حيث كانت معدلات الخطأ مرتفعة في التمييز بين الشخصية الحسدية والحسية بسبب اختلال بيانات التدريب.

بعد ذلك، أجرى Mihai Gavrilescu و Nicolae Vizireanu في عام 2018 دراسة جديدة باستخدام شبكة عصبونية ثلاثية الطبقات لتحديد الصفات الشخصية وفق نموذج العوامل الخمسة الكبرى (FFM) [4]. تضمنت الدراسة استخراج ميزات مثل خط الأساس، ميل الكلمات، ضغط الكتابة، خطوط الربط، التباعد بين السطور، وشكل الحرفين "t" و "f"، وتم استخدام مجموعة بيانات مكونة من 128 عينة. وصلت الدقة إلى 84% لصفات الانفتاح، العصبية، والاجتماعية، وحوالي 77% لصفات الضمير وقبول الآخرين.

وفي العام ذاته، طوّر كل من Vasundhara Bhade و Trupti Baraskar نموذجاً مشابهاً يعتمد على تحليل الكتابة اليدوية في بيئة غير متصلة بالإنترنت [5]. استند النموذج إلى ثلاث ميزات أساسية: الهامش الأيسر،

¹ Minnesota Multiphasic Personality Inventory

الهامش الأيمن، والمسافة بين الكلمات. أظهرت نتائج الدراسة أن النموذج قادر على التنبؤ بالشخصية بدقة 90%، إلا أن محدودية عدد الميزات المستخدمة جعلت النموذج أقل شمولية مقارنة بالدراسات التي تعتمد على تمثيلات متعددة الأبعاد.

تبع ذلك، في عام 2019، اقترحت منهجية من قبل Devesh Sony و Rakshita Sawant تعتمد على الشبكات العصبونية التلافيفية (CNN) لتحليل خصائص خط اليد [6]. تضمنت الخصائص المستخدمة ميل الكتابة، خط الأساس، الانحناء، وضغط الكتابة، كما تم تجاوز قيود الأنظمة التقليدية عبر السماح باستخدام أنواع متعددة من الأقلام.

بالتوازي، أجرى Mostafa وآخرون (2019) دراسة مقارنة على عينة مكونة من 160 نصاً باللغة العربية [7]، حيث تم اختبار عدة خوارزميات للتعلم الآلي مثل Random Forest و Simple Logistic و بالرغم من أن الدراسة نجحت في تقديم توثيق رقمي للأداء، إلا أن الدقة الإجمالية المحققة بلغت 68.67%، وهي نسبة لا تزال تعكس وجود فجوة في دقة التنبؤ، بالإضافة إلى اقتصار الدراسة على عدد محدود من الميزات الهندسية دون التعمق في ميزات خط اليد العميقة المتعلقة بلغة الكتابة. وبالمقارنة مع هذه الدراسة، يعتمد البحث الحالي على حجم بيانات أكبر (500 عينة)، إضافة إلى دمج الميزات اليدوية مع الميزات العميقة المستخرجة من نماذج مثل VGG16 و DenseNet201، مما قد يسهم في تحسين تمثيل خصائص خط اليد العربية وتعزيز القدرة التمييزية للنماذج. ومع بداية عام 2020، دمج Nijil Raj N وآخرون الشبكات العصبونية التلافيفية (CNN) مع الشبكة العصبونية متعددة الطبقات (MLP) Multi-Layer Perceptron لتصميم نظام يحقق دقة تصل إلى 92% في التنبؤ بصفات الشخصية استناداً إلى تحليل خط اليد [8]. اعتمد النموذج على سبع ميزات رئيسية تشمل خط الأساس، الهامش العلوي، ضغط القلم، حجم الأحرف، التباعد بين الأسطر، المسافة بين الكلمات، وميل الأحرف، متفوقاً بذلك على النماذج التي استخدمت ميزات محدودة أو نماذج مفردة.

كما نشر Subhankar Ghosh و Palaiahnakote Shivakumara في العام ذاته دراسة حول تطوير طريقة آلية لتحديد السلوكيات البشرية اعتماداً على تحليل خصائص الكتابة اليدوية للحروف الصغيرة من "a" إلى "z" [9]. استخدم الباحثون قاموس القواعد الخطية لبناء نظام تفاعلي أثبت كفاءة أعلى من الطرق السابقة، لكنه بقي محدوداً بعدد السلوكيات التي يمكن تحديدها.

أما في عام 2021، استخدم Nidhi Malik و Ashwin Balaji ثلاث خوارزميات تعلم آلي (SVM، خوارزمية الجار الأقرب (KNN)، K-Nearest Neighbors، الغابة العشوائية (Random Forest (RF)) لتحليل صفات الشخصية الخمسة الكبرى باستخدام عينات من الكتابة اليدوية باللغة الإنجليزية [10]. حققت الخوارزميات دقة تجاوزت 80%، مع أعلى دقة بلغت 88.91% لصفة الضمير الحي باستخدام SVM. لاحقاً، وفي عام 2022، اقترح Shalaka Prasad Deore تطوير تطبيق لتحديد الشخصية من خلال تحليل الكتابة اليدوية باللغة الدنفاغارية باستخدام الشبكات العصبونية الاصطناعية (ANN)، وبلغت دقة الاختبار 94.75% [11]. في الوقت ذاته، قدّم Marzuki Pilliang نموذجاً مبتكراً يستند إلى شبكة CNN محسنة بخوارزمية تحسين سرب الجسيمات (PSO²) للتنبؤ بالشخصية وفق نموذج HEXACO باستخدام الكتابة اليدوية باللغة الإندونيسية [12]، وحقق دقة بلغت 71.88% متفوقاً على نموذج AlexNet القياسي.

إضافة إلى ذلك، اقترح Chaubey نموذجاً يعتمد على الشبكات العصبونية التلافيفية لاستخراج ميزات الكتابة اليدوية وتحليلها تلقائياً للتنبؤ بالصفات الشخصية الخمس الرئيسية [13]. جُرب النموذج على ثلاث مجموعات بيانات (إنجليزي، هندي، ومزيج منهما)، وحقق دقة متوسطة تتراوح بين 42% و 43%. وبالانتقال إلى عام 2023، طوّرت Sarita Ambadekar و Zainab Khan نظام تعلم آلي يعتمد على آلات دعم المتجهات لتحليل الكتابة اليدوية بهدف التنبؤ بصفات الشخصية [14]. بلغ معدل الدقة 96%، مما يعكس فعالية النموذج المقترح.

أخيراً، في عام 2025، نشر Daniel Gagi و Dorin Sendrescu ورقة علمية تناولت تطوير نظام لاستخراج خصائص الكتابة اليدوية وربطها بمؤشرات Myers-Briggs باستخدام الشبكات العصبونية التلافيفية [15]. أظهرت النتائج دقة تراوحت بين 89% و 96% في التعرف على ميزات الخط، و 83% إلى 91% في تصنيف المؤشرات الشخصية.

وعلى الرغم من التنوع الكبير في المنهجيات ومجموعات البيانات المستخدمة في الدراسات السابقة، إلا أن تحليل خط اليد باللغة العربية لا يزال محدوداً نسبياً، مما يشكل فجوة بحثية واضحة، ويبرر الحاجة إلى تطوير نماذج أكثر شمولية تعتمد على دمج الميزات اليدوية والعميقة لمعالجة هذا النوع من البيانات.

2. منهجية البحث

يعتمد هذا البحث على منهجية تجريبية تهدف إلى بناء نماذج تصنيف فعالة لتحديد صفات الشخصية الخمس الكبرى (Big Five Personality Traits) من خلال تحليل عينات من خط اليد العربي. تتكون المنهجية من سلسلة من المراحل المترابطة تبدأ بجمع البيانات الأولية، مروراً باستخراج الميزات وتحليلها، وانتهاءً بتدريب النماذج واختبارها. وقد تم تنفيذ عدة سيناريوهات تجريبية تجمع بين أنواع مختلفة من الميزات بهدف تقييم تأثير كل نوع منها في أداء نماذج التصنيف.

في المرحلة الأولى، قمنا بجمع بيانات خط اليد من مشاركين متطوعين خضعوا لاختبار الشخصية وفق نموذج العوامل الخمسة (FFM). بعد ذلك، تم تطبيق تقنيات معالجة الصور لاستخراج ميزات خط اليد، والتي شملت ثلاثة أنواع رئيسية: الميزات اليدوية (Handcrafted Features) مثل ميل الخط، المسافات بين الكلمات، الخط الأساسي للكتابة، وغيرها من الخصائص الهندسية، بالإضافة إلى الميزات العميقة المستخرجة تلقائياً باستخدام نماذج التعلم العميق المدربة مسبقاً، حيث تم استخدام النموذجين (VGG16 و DenseNet201) لاستخلاص تمثيلات عميقة من صور الكتابة اليدوية اعتماداً على الطبقات العميقة في هذه الشبكات. ثم بعد ذلك استخدمنا خوارزمية الغابة العشوائية (Random Forest) كنموذج تصنيف أساسي، وقمنا باختبار أداء النموذج لكل صفة من صفات الشخصية على حدة. وللتعامل مع مشكلة عدم توازن البيانات بين الفئات المختلفة، تم تطبيق تقنية SMOTE لإعادة توازن البيانات وتحسين قدرة النماذج على التعميم. تم تقييم كل نموذج باستخدام عدة مقاييس معيارية مثل الصحة (Accuracy)، معامل F1-Score، ومصفوفة الالتباس Confusion Matrix، حيث تم توثيق وتحليل أداء النماذج في كل سيناريو مقارنةً ببقية السيناريوهات.

3. بناء وجمع Dataset

تم تطوير مجموعة البيانات المستخدمة في هذا البحث خصيصاً لغرض تحليل الشخصية استناداً إلى الكتابة اليدوية باللغة العربية. شملت عملية جمع البيانات مرحلتين أساسيتين: أولاً، الإجابة على أسئلة استبيان الشخصية وفق نموذج العوامل الخمسة الكبرى (FFM)، حيث تم الاعتماد على اختبار العوامل الخمسة الكبرى (IPIP-3 BFFMT) الذي طوره جولد برج ولويس عام 1992 كأداة لجمع بيانات الصفات الخمسة الأساسية [16]. فهو يعتبر اختباراً ذاتياً يقيس الصفات الشخصية الخمسة الأساسية. وثانياً، تقديم عينات مكتوبة بخط اليد من قبل نفس المشاركين.

تم توحيد النص المكتوب بين جميع المشاركين، حيث طُلب من كل فرد كتابة نفس العينة النصية المحددة مسبقاً، وذلك بهدف تقليل تأثير اختلاف المحتوى اللغوي على الميزات المستخرجة وتحقيق قدر أكبر من الاتساق بين العينات. أما بالنسبة لأداة الكتابة، فلم يتم فرض نوع محدد من الأقلام على المشاركين، وذلك لمحاكاة ظروف الكتابة الطبيعية. ويهدف الحد من تأثير اختلاف نوع القلم على عملية التصنيف، تم التركيز على الميزات الهندسية والبنوية الأقل تأثراً بالعوامل الفيزيائية المرتبطة بأداة الكتابة. كما تم استخدام أوراق بيضاء عادية غير مسطرة لجميع المشاركين، بهدف تقليل تأثير الخلفية على عملية المعالجة واستخراج الميزات.

بعد جمع العينات، جرى تحويل صفحات الكتابة اليدوية إلى صور رقمية باستخدام تطبيق CamScanner عبر كاميرا الهاتف المحمول. وتم الحفاظ على موضع تصوير ثابت وظروف تصوير متقاربة قدر الإمكان لجميع المشاركين، بهدف ضمان تجانس الصور وتقليل تأثير اختلاف زاوية التصوير أو الإضاءة على عملية استخراج الميزات. بلغ عدد المشاركين في الدراسة 500 فرد ولضمان تنوع البيانات ودقتها، قمنا بتوزيع الاستبيان على فئات متنوعة من الأفراد من مختلف الأعمار حيث كانت الفئة العمرية للمشاركين تتراوح بين 18 ≤ 45 ومن خلفيات تعليمية وثقافية متنوعة مع الإشارة أن الغالبية المستهدفة كانت فئة طلاب الجامعة من كليات الهندسة.

في إطار تطبيق استبيان الصفات الشخصية الخمس الكبرى (IPIP-BFFMT) على المشاركين، قمنا بتحويل الاستبيان من اللغة الإنجليزية إلى اللغة العربية لضمان سهولة فهم الأسئلة ودقة إجابات المشاركين. وقد تمت عملية الترجمة بعناية وتم تدقيقها في قسم اللغة الانكليزية في المعهد العالي للغات في جامعة اللاذقية (تشرين سابقاً)، حيث تم الالتزام بالمعايير اللغوية الدقيقة والحفاظ على المعنى الأصلي للأسئلة والعبارات لضمان بقاء الأداة البحثية متسقة مع النسخة الأصلية.

يتألف الاستبيان من 50 سؤالاً لقياس الصفات الشخصية الخمس الأساسية، حيث يحدد المشارك درجة موافقته على كل عبارة باستخدام مقياس ليكرت الخماسي (أبداً، قليلاً، أحياناً، كثيراً، دائماً). ومن أمثلة العبارات المستخدمة: "هل تشعر بأنك ممتع ومسلّي عند تواجدك في حفلة أو أي نشاط اجتماعي" لقياس صفة الاجتماعية (E)، "هل تشعر بالراحة النفسية غالباً" لقياس صفة العصبية (N)، "هل لديك خيال خصب" لقياس صفة الانفتاح على التجربة (O)، "هل تحب تنظيم أمورك" لقياس صفة الضمير (C).

³ International Personality Item Pool- Big Five Factor Model Test

بعد جمع الإجابات، تم حساب درجة كل صفة اعتماداً على مفاتيح التصحيح الخاصة باختبار (IPIP-BFFMT)، مع مراعاة التصحيح العكسي لبعض الأسئلة، ومن ثم تم تحديد مستوى كل صفة لدى المشارك واستخدامه كوسم (Label) لعينة الكتابة اليدوية الخاصة به.

3.1 تقدير التصنيفات المعيارية لاختبار IPIP-BFFMT

لا تتوفر معايير وطنية لاختبار الشخصية IPIP-50 التي يمكن استخدامها لتصنيف الدرجات في كل صفة إلى "مرتفع" و"متوسط" و"منخفض" [17]. وبحسب رأي جولديبرج [18]، فإن معظم المعايير الوطنية قد تكون مضللة، حيث يقترح أنه في حال الحاجة إلى معايير خاصة بمقاييس IPIP، يجب على المستخدمين تطوير معايير محلية بناءً على عيناتهم الخاصة.

في هذه الدراسة، تم استخدام بيانات من 500 مشارك لإنشاء تصنيفات معيارية محلية من ثلاثة مستويات (مرتفع، متوسط، منخفض) لكل من الصفات الشخصية الخمس التي يقيسها IPIP-50 وقد استندت التصنيفات الثلاثة إلى مقياس "ستانين" القياسي (stanine scale)، حيث تفسر الدرجات وفقاً للتقسيم التالي: (من الدرجة 1 إلى الدرجة 3) تعتبر منخفضة، و (من 4 إلى 6) تعتبر متوسطة، بينما الدرجات (من 7 إلى 9) تصنف على أنها مرتفعة [19].

يتم عرض المعايير الناتجة للصفات الخمسة في الجدول 1

جدول 1 التصنيفات المعيارية لنموذج IPIP-BFFMT

	Extraversion (n=500) M (SD)	Agreeableness (n = 500) M (SD)	Conscientiousness (n=500) M (SD)	Neuroticism (n=500) M (SD)	Openness to Experience (n=500) M (SD)
	22.29 (6.09)	27.04 (5.71)	26.37 (6.53)	20.30 (7.18)	26.25 (4.93)
Low	0-15	0-20	0-19	0-12	0-20
Medium	16-28	21-33	20-33	13-28	21-31
High	29-40	34-40	34-40	29-40	32-40

عند تفريغ البيانات وتنظيمها، لقد تبين انحياز واضح في توزيع العينات بين مستويات كل صفة. حيث كانت الغالبية العظمى من المشاركين في النطاق المتوسط لكل صفة شخصية، بينما كان عدد العينات في المستويين المرتفع والمنخفض محدوداً. ويعود هذا التوزيع غير المتوازن إلى الطبيعة الواقعية للصفات النفسية في المجتمع، حيث يصعب أثناء جمع البيانات التحكم بمستوى وجود كل صفة لدى المشاركين. هذا الخلل في التوزيع يحتم ضرورة استخدام تقنيات زيادة البيانات لمعالجة هذا التفاوت وضمان تدريب نماذج أكثر توازناً في التصنيف. حيث تم استخدام تقنية الزيادة الاصطناعية للفئة الأقل تمثيلاً (SMOTE). سيتم دراسة تأثير هذه التقنية على دقة التصنيف في قسم النتائج.

4. استخراج الميزات

لقد اعتمدنا في دراستنا على عدة أساليب لاستخراج ميزات الكتابة اليدوية من الصور التي تم جمعها من المشاركين، حيث يجمع هذا النهج الهجين بين دقة الميزات التقليدية القائمة على المعرفة البشرية وقوة التعلم العميق في اكتشاف الأنماط غير الظاهرة، مما يعزز قدرة النموذج على ربط الميزات الخطية بالخصائص النفسية

بدقة أعلى، مع مراعاة خصوصيات اللغة العربية وتركيبية حروفها الفريدة. تُستخدم النتائج لبناء نموذج تنبؤي قادر على تحليل الشخصية، مع إمكانية تطبيقه في مجالات متعددة.

4.1 الميزات اليدوية (Handcrafted Features)

وهي مجموعة من الخصائص المستخرجة باستخدام تقنيات معالجة الصور والخوارزميات التقليدية، والتي تعكس ميزات هندسية وبنوية في الكتابة، حيث قمنا باستخراج مجموعة هامة من الميزات التي تعكس الأسلوب والطابع الخاص للكتابة والتي تساعد في عملية تصنيف الشخصية للكاتب حيث تم استخراج مجموعة من الخصائص البصرية والهندسية من صور الكتابة اليدوية باستخدام تقنيات معالجة الصور وتشمل هذه الميزات [20]:

1. ميل الخط (Slant Angle): تم حسابه من خلال تطبيق تحويل هوف (Hough Transform) على الحواف المائلة للحروف (معادلة 1)، حيث يتم استخراج الزوايا المميزة ثم حساب المتوسط.

$$slant = \sum_{i=1}^n \theta_i$$

2. الخط الأساسي (Baseline): يُحسب باستخدام تحويل هوف (Hough Transform)، ويأخذ متوسط قيمة ρ للخطوط المكتشفة (معادلة 2).

$$Baseline = \frac{1}{n} \sum_{i=1}^n \rho_i$$

3. الهامش العلوي (Top Margin): يُقاس من أعلى الصفحة إلى أول سطر مكتوب يُحسب كموقع أول صف (Row) في الإسقاط الأفقي تتجاوز فيه القيمة متوسط الإسقاط، ويمثل بداية الكتابة (معادلة 3).

$$Top\ Margin = \min\{i \mid proj_{horizontal}(i) > \mu\}$$

4. حجم الحروف (Letter Size): يُحسب كمعوسط ارتفاع المستطيلات المحيطة بكل Contour يمثل الأحرف (معادلة 4).

$$Letter\ Size = \frac{1}{n} \sum_{i=1}^n h_i$$

5. تباعد الأسطر (Line Spacing): يُستخرج من متوسط المسافات بين مواقع الأسطر المكتوبة باستخدام الإسقاط الأفقي (معادلة 5).

$$Line\ Spacing = mean(\Delta_{y_i})$$

6. المسافة بين الكلمات (Word Spacing): مشابه لتباعد الأسطر، لكنه يُحسب من الإسقاط العمودي (معادلة 6).

$$Word\ Spacing = mean(\Delta_{x_i})$$

7. الطاقة (Energy): تمثل درجة انتظام الصورة، إذا كانت الكتابة اليدوية تحتوي على نمط منتظم ومتكرر (مثل ضغط موحد للحروف، أو حواف واضحة متكررة)، فستكون الطاقة عالية. أما إذا كانت الكتابة غير منتظمة أو مليئة بالتقلبات العشوائية، فستكون الطاقة منخفضة (معادلة 7).

$$Energy = \sum_i \sum_j p(i,j)^2$$

حيث:

✓ $P(i, j)$: عنصر من مصفوفة الإزاحة الرمادية (GLCM)، ويمثل احتمالية ظهور زوج من القيم الرمادية i و j جنباً إلى جنب في اتجاه معين (أفقياً، عمودياً، قطرياً)، عند مسافة معينة داخل الصورة.

✓ i, j : مؤشرات الصفوف والأعمدة في مصفوفة GLCM، وتمثل مستويات الرمادي المختلفة.
8. كثافة المحيط (Contour Density): تُقاس هذه الميزة بنسبة المساحة التي يشغلها النص المكتوب (المحيطات) إلى المساحة الإجمالية للصورة. تُعطي هذه الميزة مؤشراً على مدى كثافة الكتابة، والذي يمكن أن يرتبط بخصائص تنظيمية أو نفسية معينة لدى الكاتب (معادلة 8).

$$\text{Contour Density} = \frac{\sum_{i=1}^n A_i}{W * H}$$

حيث :

✓ A_i تمثل مساحة كل محيط.

✓ $W * H$ مساحة الصورة الكلية (العرض × الارتفاع).

4.2 الميزات العميقة (Deep Features)

تم استخدام نماذج التعلم العميق المدربة مسبقاً لاستخراج الميزات العميقة من صور الكتابة اليدوية. وقد تم الاعتماد على شبكات عصبونية تلافيفية عميقة أثبتت كفاءة عالية في استخراج الميزات البصرية من الصور، ومن أبرزها (DenseNet201 و VGG16). تم تطوير نموذج VGG16 من قبل مجموعة Visual Geometry Group في جامعة أكسفورد [21]، ويتكون من 16 طبقة ذات أوزان قابلة للتعلم تشمل طبقات تلافيفية وطبقات مترابطة بالكامل، ويضم عدداً كبيراً من المعاملات القابلة للتدريب. أما نموذج DenseNet201 فيعتمد على بنية اتصال كثيف بين الطبقات (Dense Connectivity)، حيث ترتبط كل طبقة بالطبقات السابقة لها، الأمر الذي يساهم في تحسين تدفق المعلومات داخل الشبكة والتقليل من مشكلة تلاشي التدرج أثناء التدريب.

استُخدمت هذه النماذج كمستخرجات للميزات (Feature Extractors)، حيث تُستخلص تمثيلات عميقة من الطبقات العميقة في الشبكة لتشكيل متجهات عددية تعبر عن الأنماط البصرية الدقيقة الموجودة في صور الكتابة اليدوية. بعد ذلك تُستخدم هذه الميزات كمدخلات لخوارزمية التصنيف Random Forest لبناء نموذج قادر على تصنيف صفات الشخصية الخمس الكبرى، مستفيداً من قدرة هذه الخوارزمية على التعامل مع البيانات عالية الأبعاد وتحليل أهمية الميزات المختلفة في عملية التصنيف.

5. تصميم التجارب وبناء النماذج

تم تصميم سلسلة من التجارب المنظمة لتقييم قدرة النماذج المختلفة على تصنيف الصفات الشخصية الخمس الكبرى استناداً إلى ميزات مستخرجة من الكتابة اليدوية. شملت التجارب عدة سيناريوهات مختلفة، تم فيها اختبار تأثير نوع الميزات (يدوية، عميقة، أو مدمجة) وتقنيات تحسين البيانات مثل التوازن باستخدام SMOTE، بهدف الوصول إلى نموذج تصنيفي أكثر دقة وموثوقية.

تضمنت التجارب استخدام أنواع متعددة من الميزات، بما في ذلك الميزات اليدوية (Handcrafted Features) والميزات العميقة المستخرجة باستخدام نماذج التعلم العميق مثل (DenseNet201 و VGG16)، بالإضافة إلى بعض السيناريوهات التي تعتمد على دمج هذه الميزات معاً. كما تم اعتماد تقنية SMOTE لمعالجة مشكلة عدم توازن الفئات في مجموعة البيانات. حيث طُبقت على بيانات التدريب فقط بعد عملية التقسيم، وذلك لتجنب مشكلة

تسرب البيانات (Data Leakage) وضمان تقييم واقعي لأداء النموذج. وقد هدفت هذه التجارب إلى دراسة تأثير كل نوع من الميزات على أداء نماذج التصنيف والوصول إلى نموذج تنبؤي أكثر دقة وموثوقية في تحديد صفات الشخصية الخمس الكبرى.


5.1 خوارزمية Random Forest وتحسين الأداء باستخدام Grid Search

تُعد خوارزمية هذه الخوارزمية إحدى أكثر تقنيات التعلم الآلي انتشاراً وفعالية في مشكلات التصنيف متعددة الأبعاد لما تتميز به من مرونة واستقرار في الأداء، وقدرة على التعامل مع البيانات ذات الطبيعة غير الخطية وغير المتوازنة. تقوم هذه الخوارزمية على مبدأ التجميع (Ensemble Learning)، حيث يتم بناء عدد كبير من أشجار القرار (Decision Trees) بشكل عشوائي، ثم تُدمج نتائجها بأخذ متوسط مخرجات أشجار مختلفة للوصول إلى قرار نهائي أكثر دقة واستقراراً بالإضافة إلى تقليل الإفراط في التجهيز وتحسين الأداء التنبؤي [23] [22]. تعتمد Random Forest على آلية تُعرف بالتصويت الجماعي (Majority Voting) في حالة التصنيف، حيث تُعطى النتيجة الأكثر شيوعاً بين الأشجار كمخرج نهائي للنموذج. هذه البنية تقلل من احتمالية التحيز أو فرط التلبيق في التعلم (Overfitting) الذي قد يصيب النماذج الفردية، وتمنح النموذج قوة تعميمية أعلى عند تطبيقه على بيانات جديدة [22]. كما تسمح الخوارزمية بتقييم أهمية كل ميزة (Feature Importance) من خلال تحليل مدى مساهمة كل متغير في تقليل الخطأ خلال بناء الأشجار.

وفي سياق هذا البحث، يعود سبب اختيار خوارزمية Random Forest لقدرتها على التعامل مع كل من الميزات العددية المستخرجة يدوياً، والتمثيلات العميقة الناتجة عن الشبكات العصبونية، كما أنها تتسم بكفاءة حسابية مناسبة لمشاريع ذات حجم بيانات متوسط. وقد مكّنا استخدام Grid Search من الوصول إلى نموذج Forest Random يتمتع بأداء متوازن عبر مختلف صفات الشخصية، من خلال ضبط الحصول على أفضل القيم لكل الالموسطات الفائقة hyperparameters. وبهذا شكّلت هذه التقنية خطوة جوهرية نحو بناء نموذج أكثر موثوقية وقابلية للتعميم في سياق تحليل الشخصية من خلال خط اليد.

5.2 سيناريوهات العمل

من أجل تقييم تأثير مصادر الميزات وطرق معالجة التوازن، تم تصميم سيناريوهين تجريبيين للعمل، حيث يختبر كل سيناريو مجموعة معينة من الميزات (يدوية، عميقة، أو مدمجة) إلى جانب آليات معالجة عدم التوازن (البيانات الأصلية، SMOTE). وتم تدريب نموذج مستقل لكل صفة من صفات الشخصية الخمس (E, A, C, O) في كل سيناريو، مما يسمح بإجراء مقارنة دقيقة لأداء النماذج تبعاً لاختلاف طريقة التحضير والميزات المدخلة. تم تقسيم البيانات إلى مجموعتي تدريب واختبار بنسبة 80% و 20% على التوالي، مع الحفاظ قدر الإمكان على التوزيع النسبي للفئات المختلفة. كما تم استخدام أسلوب التحقق المتقاطع (Cross Validation) ضمن Grid Search أثناء عملية التدريب بهدف تقليل خطر فرط التلبيق في التعلم وتحسين قدرة النموذج على التعميم. فيما يلي يعبر (الشكل 1) عن آلية العمل بشكل عام، حيث تم تطبيق هذه المنهجية في بناء نموذج لكل من هذه الصفات، و تنطبق هذه الآلية على كل صفة من الصفات الخمسة.



الشكل 1 المخطط العام لسيناريوهات العمل

سنعرض آلية عمل كل سيناريو كالتالي:

تضمّن البحث سيناريوهين رئيسيين للعمل لاختبار أداء نماذج تصنيف الشخصية من خلال الكتابة اليدوية، باستخدام ميزات يدوية وميزات عميقة:

➤ السيناريو الأول: يهدف هذا السيناريو إلى تدريب النماذج باستخدام مجموعة البيانات الأصلية المكونة من (500) عينة غير متوازنة دون إجراء أي عملية موازنة للبيانات.

➤ السيناريو الثاني: يهدف هذا السيناريو إلى تحسين أداء النماذج ومعالجة مشكلة عدم توازن البيانات من خلال تطبيق تقنية SMOTE لزيادة حجم البيانات ومعالجة مشكلة عدم التوازن بين الفئات.

في كل من السيناريوهين الأول والثاني، تم تقييم خمسة نماذج مختلفة اعتماداً على أنواع متعددة من الميزات وهي:

❖ النموذج الأول: يعتمد على الميزات اليدوية (Handcrafted Features) فقط.

❖ النموذج الثاني: يعتمد على الميزات العميقة المستخرجة من شبكة VGG16.

❖ النموذج الثالث: يعتمد على دمج الميزات (Handcrafted Features & VGG16)، حيث يجمع بين

الميزات اليدوية وميزات VGG16.

❖ النموذج الرابع: يعتمد على الميزات العميقة المستخرجة من شبكة DenseNet201.

❖ النموذج الخامس: يعتمد على دمج الميزات اليدوية مع الميزات العميقة المستخرجة من شبكة

DenseNet201.

بعد الانتهاء من عملية تدريب نماذج التصنيف الخاصة بكل صفة من صفات الشخصية الخمسة باستخدام خوارزمية Random Forest المحسنة بواسطة تقنية Grid Search، تم تقييم أداء هذه النماذج وفقاً لمجموعة من مؤشرات الأداء القياسية، شملت الصحة (Accuracy)، الاسترجاع (Recall)، ومقياس (F1-Score). وفي المرحلة النهائية، تم المقارنة بين نتائج جميع السيناريوهات واختيار أفضل نموذج لكل صفة من صفات الشخصية الخمس بالاعتماد على أعلى قيمة تم تحقيقها لمؤشر F1-Score، وذلك لكونه المؤشر الأكثر توازناً في الحالات التي تعاني من عدم توازن بين الفئات.

النتائج والمناقشة:

من خلال هذا التصميم التجريبي، تمكنا من مقارنة تأثير نوع الميزات وطرق التوازن على قدرة نماذج Random Forest على التمييز بين درجات الصفات الشخصية المختلفة، مما يمكن من استخلاص استنتاجات موضوعية حول أفضل الاستراتيجيات لاستخراج وتوازن البيانات في سياق تحليل الشخصية من خلال خط اليد. فيما يلي سيتم عرض قيم كل من الصحة ومقياس F1-Score لكل نموذج تم تطبيقه من أجل تصنيف الصفات الخمسة وذلك في جدول خاص بكل صفة يعرض فيه نتائج تصنيف الخاصة بنماذج هذه الصفة مع رسم بياني يوضح الفروقات بين أداء كل من النماذج:


1. صفة الاجتماعية (Extraversion)

الجدول (2) يظهر قيم كل الصحة ومقياس F1-Score التي تعكس أداء سيناريوهات العمل من أجل تصنيف صفة الاجتماعية E.

جدول 2 نتائج سيناريوهات العمل من أجل صفة الاجتماعية

Feature Extraction	Without Augmentation		With Smote Augmentation	
	Accuracy	F1-Score	Accuracy	F1-Score
HW	75%	64%	61%	61%
VGG	74%	64%	74%	64%
VGG & HW	75%	64%	74%	64%
DNS	80%	75%	81%	76%
HW&DNS	81%	76%	80%	75%

يوضح الشكل 2 أدناه المقارنة بين نتائج النماذج المبنية باستخدام الميزات اليدوية (HW)، الميزات العميقة المستخرجة عبر VGG16، ودمج كلا النوعين من الميزات، بالإضافة إلى الميزات العميقة المستخرجة عبر DenseNet201، ودمج الميزات اليدوية مع ميزات DenseNet201 وذلك ضمن حالتين للبيانات: البيانات الأصلية، البيانات المتوازنة باستخدام SMOTE



الشكل 2 مخطط نتائج نماذج التصنيف لصفة الاجتماعية

تشير النتائج الخاصة بصفة الاجتماعية إلى أن أفضل أداء تحقق عند استخدام الميزات العميقة المستخرجة من نموذج DenseNet201 والميزات المدمجة، حيث سجلت أعلى قيمة لمقياس F1-Score بلغت (76%) عند

استخدام (DNS) مع تطبيق SMOTE، بينما حققت الميزات المدمجة (HW & DNS) قيمة قريبة بلغت (75%) مع SMOTE و(76%) باستخدام البيانات الأصلية غير المتوازنة.

أما بالنسبة لمقياس الصحة (Accuracy)، فقد حققت الميزات المدمجة (HW & DNS) أعلى أداء بلغ (81%) عند استخدام البيانات الأصلية، كما حافظت على أداء مرتفع بلغ (80%) بعد تطبيق SMOTE، في حين حققت ميزات (DNS) دقة بلغت (81%) عند استخدام البيانات الأصلية و(80%) عند استخدام البيانات المتوازنة. بالمقابل، سجلت الميزات اليدوية (HW) أضعف أداء، حيث بلغت قيمة F1-Score والصحة (61%) عند استخدام البيانات المتوازنة.

وتشير هذه النتائج إلى أن دمج الميزات اليدوية مع الميزات العميقة ساهم في بناء تمثيل أكثر غنى واستقراراً لخصائص الكتابة اليدوية، الأمر الذي مكّن النموذج من الحفاظ على أداء مرتفع حتى عند استخدام البيانات الأصلية غير المتوازنة، مما يدل على أن جودة تمثيل الميزات قد تكون أحياناً أكثر تأثيراً من عملية إعادة التوازن نفسها.


2. صفة الود (Agreeableness)

الجدول (3) يظهر قيم كل الصحة ومقياس F1-Score التي تعكس أداء سيناريوهات العمل من أجل تصنيف صفة الود A

جدول 3 نتائج سيناريوهات العمل من أجل صفة الود

Feature Extraction	Without Augmentation		With Smote Augmentation	
	Accuracy	F1-Score	Accuracy	F1-Score
HW	76%	66%	63%	64%
VGG	75%	65%	76%	67%
VGG & HW	76%	66%	77%	68%
DNS	79%	73%	81%	76%
HW&DNS	79%	73%	80%	74%

كما ويمثل الشكل 3 المقارنة بين نتائج النماذج بالنسبة لصفة الود من خلال مقاييس الصحة و F1-Score.



الشكل 3 مخطط نتائج نماذج التصنيف لصفة الاجتماعية

كما هو موضح في الشكل 3، فإن أفضل أداء تحقق عند استخدام الميزات العميقة المستخرجة من نموذج DenseNet201، حيث سجلت أعلى قيمة لمقياس F1-Score بلغت (76%) مع تطبيق SMOTE، بينما حققت الميزات المدمجة (HW & DNS) بقيمة بلغت (74%) بعد التوازن. أما بالنسبة لمقياس الصحة (Accuracy)، فقد سجلت ميزات (DNS) أعلى أداء بلغ (81%) بعد تطبيق SMOTE، تليها الميزات المدمجة (HW & DNS) بنسبة (80%). بالمقابل، سجلت الميزات اليدوية (HW) أضعف أداء، حيث بلغت قيمة F1-Score (64%) ومقياس الصحة (63%) بعد تطبيق SMOTE. وتوضح هذه النتائج أن الميزات العميقة كانت أكثر قدرة على تمثيل الأنماط المرتبطة بصفة الود مقارنة بالميزات اليدوية التقليدية، كما أن تطبيق SMOTE ساهم في تحسين قدرة النموذج على التمييز بين الفئات المختلفة، خاصة عند استخدام الميزات العميقة أو دمجها مع الميزات اليدوية.


3. صفة الضمير (Conscientiousness)

الجدول (4) يظهر قيم كل الصحة ومقياس F1-Score التي تعكس أداء سيناريوهات العمل المطبقة من أجل تصنيف صفة الضمير الحي C.

جدول 4 نتائج سيناريوهات العمل من أجل صفة الضمير

Feature extraction	Without Augmentation		With Smote Augmentation	
	Accuracy	F1-Score	Accuracy	F1-Score
VGG	72%	60%	53%	55%
HW	72%	60%	72%	60%
VGG & HW	72%	60%	71%	61%
DNS	74%	65%	76%	71%
HW&DNS	78%	72%	75%	70%

يوضح الشكل أدناه المقارنة بين نتائج النماذج بالنسبة لصفة الضمير من خلال مقاييس الصحة و F1-Score.



الشكل 4 مخطط نتائج نماذج التصنيف لصفة الضمير

من الشكل 4 نلاحظ أنه حصلنا على أفضل أداء تحقق عند استخدام الميزات المدمجة (HW & DNS) على البيانات الأصلية غير المتوازنة، حيث سجلت أعلى قيمة للصحة (Accuracy) بلغت (78%)، إلى جانب أعلى

قيمة لمقياس F1-Score بلغت (72%). كما حققت الميزات العميقة المستخرجة من نموذج DenseNet201 أداءً مرتفعاً بعد تطبيق SMOTE، حيث بلغت قيمة F1-Score حوالي (71%) ومقياس الصحة (76%). في المقابل، أظهرت الميزات اليدوية (HW) والميزات المستخرجة باستخدام VGG أداءً أقل نسبياً، حيث تراوحت قيم F1-Score بين (55%-60%)، بينما بلغت قيم مقياس الصحة حوالي (72%) في معظم الحالات. كما يُلاحظ أن دمج الميزات اليدوية مع ميزات VGG لم يحقق تحسناً كبيراً مقارنة باستخدام الميزات بشكل منفصل.


4. صفة الاستقرار النفسي (N)

الجدول (5) يظهر قيم كل الصحة ومقياس F1-Score التي تعكس أداء سيناريوهات العمل المطبقة من أجل تصنيف صفة العصبية N.

جدول 5 نتائج سيناريوهات العمل من أجل صفة العصبية

Feature extraction	Without Augmentation		With Smote Augmentation	
	Accuracy	F1-Score	Accuracy	F1-Score
HW	74%	63%	56%	57%
VGG	74%	63%	70%	61%
VGG & HW	73%	62%	74%	65%
DNS	79%	73%	74%	63%
HW&DNS	79%	73%	79%	73%

يوضح الشكل أدناه المقارنة بين نتائج النماذج التي تم تنفيذها لتصنيف صفة العصبية من خلال مقاييس الصحة و F1-Score.



الشكل 5 مخطط نتائج نماذج التصنيف لصفة العصبية

نلاحظ من الشكل 5 أن أفضل أداء تحقق عند استخدام الميزات المدمجة (HW & DNS)، حيث سجلت أعلى قيمة لمقياس F1-Score بلغت (73%)، سواء عند استخدام البيانات الأصلية أو بعد تطبيق SMOTE، كما حققت أعلى قيمة لمقياس الصحة (Accuracy) بلغت (79%) في الحالتين أيضاً، مما يدل على استقرار أداء النموذج عند استخدام هذا النوع من الميزات.

كما حققت الميزات العميقة المستخرجة من نموذج DenseNet201 أداءً جيداً على البيانات الأصلية، حيث بلغت قيمة F1-Score حوالي (73%) و مقياس الصحة (79%)، إلا أن الأداء انخفض بعد تطبيق SMOTE

ليصل إلى (63%) و (74%) على التوالي. بالمقابل، أظهرت الميزات اليدوية (HW) أضعف أداء، حيث بلغت قيمة (57%) F1-Score ومقياس الصحة (56%) بعد تطبيق SMOTE. وتوضح هذه النتائج أن دمج الميزات اليدوية مع الميزات العميقة ساهم في تحقيق أداء أكثر استقراراً في تصنيف صفة الاستقرار النفسي مقارنة باستخدام كل نوع من الميزات بشكل منفصل.


5. صفة الانفتاح على التجارب (Open to experience)

الجدول (6) يظهر قيم كل الصحة ومقياس F1-Score التي تعكس أداء السيناريوهات التسعة المطبقة من أجل تصنيف صفة الاجتماعية "O".

جدول 6 نتائج سيناريوهات العمل من أجل صفة الانفتاح على التجارب

Feature extraction	Without Augmentation		With Smote Augmentation	
	Accuracy	F1-Score	Accuracy	F1-Score
VGG	71%	60%	57%	57%
HW	70%	60%	72%	63%
VGG & HW	70%	60%	66%	58%
DNS	77%	70%	77%	72%
HW&DNS	75%	68%	76%	71%

يوضح الشكل 6 المقارنة بين نتائج النماذج التي تم تنفيذها لتصنيف صفة الانفتاح على التجارب من خلال مقاييس الصحة و F1-Score.




الشكل 6 نتائج نماذج التصنيف لصفة الانفتاح على التجارب

تشير النتائج الخاصة بصفة الانفتاح على التجارب إلى أن أفضل أداء تحقق عند استخدام الميزات العميقة المستخرجة من نموذج DenseNet201، حيث سجلت أعلى قيمة لمقياس F1-Score بلغت (72%) بعد تطبيق SMOTE، وقيمة مقياس الصحة (Accuracy) بلغت (77%). كما حققت الميزات المدمجة (HW & DNS) أداءً مرتفعاً أيضاً، حيث بلغت قيمة F1-Score حوالي (71%) ومقياس الصحة (76%) بعد موازنة البيانات. في المقابل، أظهرت الميزات المستخرجة باستخدام VGG والميزات المدمجة معه أداءً أقل نسبياً، حيث تراوحت قيم F1-Score بين (57%-60%)، بينما تراوحت قيم مقياس الصحة بين (57%-71%). كما حققت الميزات

اليديوية (HW) أداءً متوسطاً مقارنةً ببقية الميزات، حيث بلغت قيمة (F1-Score (%63 ومقياس الصحة (%72) بعد تطبيق SMOTE.

وتوضح هذه النتائج أن الميزات العميقة، وخاصة DenseNet201، كانت أكثر قدرة على تمثيل الأنماط المرتبطة بصفة الانفتاح على التجارب مقارنة ببقية أنواع الميزات، مما ساهم في تحسين أداء النموذج في عملية التصنيف. يُقدم الشكل أدناه مقارنة شاملة لأداء النماذج الأفضل عبر جميع الصفات الخمس، ملخصاً أهم النتائج التي تم التوصل إليها. يُظهر التحليل أن النماذج حققت أداءً متميزاً ومتقارباً في تصنيف جميع الصفات، حيث تجاوزت قيمة مقياس الصحة (Accuracy) في جميع الحالات (%77). وقد برزت صفتا الود والاجتماعية كأفضل أداءً، حيث حقق كل منهما دقة بلغت (%81). أما من حيث مقياس (F1-Score)، سجلت (%76) في كل من صفة الود والاجتماعية. تُشير هذه النتائج إلى أن الميزات العميقة والمدمجة المستخدمة في أفضل النماذج فعالة في التصنيف بجميع أبعاد الشخصية الخمسة، مع تفوق طفيف في تصنيف صفات الود والاجتماعية.

وتتوافق هذه النتائج مع الاتجاهات الحديثة في الدراسات المعتمدة على الشبكات العصبونية التلافيفية، مثل دراسة Nijil Raj N وآخرون (2020)، والتي أظهرت تحسناً في أداء التصنيف عند استخدام النماذج الهجينة والميزات العميقة. كما تتفوق النتائج الحالية على دراسة Mostafa وآخرون (2019)، التي حققت دقة بلغت %68.67 باستخدام ميزات هندسية تقليدية، مما يعكس أهمية استخدام التمثيلات العميقة وتقنيات معالجة عدم توازن البيانات في تحسين أداء تصنيف الشخصية من خلال خط اليد العربي.



الشكل 7 مقارنة أداء أفضل نموذج لكل صفة من الصفات الشخصية الخمسة

الاستنتاجات والتوصيات:

أظهرت نتائج البحث أن تحليل خط اليد العربي باستخدام تقنيات الذكاء الاصطناعي يمكن أن يعطي مؤشرات جيدة عن بعض صفات الشخصية، مع اختلاف في دقة التصنيف بين الصفات المختلفة، حيث كانت بعض الصفات أسهل في التمييز من غيرها بسبب وضوح انعكاسها على خصائص الكتابة اليدوية مثل التنظيم والتباعد وشكل الكتابة. كما بيّنت النتائج وجود علاقة قابلة للقياس بين خصائص الكتابة اليدوية والصفات النفسية، مما يؤكد فعالية هذا الأسلوب في تصنيف الصفات الخمس الكبرى للشخصية.

كما أظهرت النتائج أن استخدام الميزات العميقة المستخرجة باستخدام نماذج التعلم العميق ساهم في تحسين الأداء مقارنة بالميزات اليدوية، خصوصاً عند معالجة مشكلة عدم توازن البيانات باستخدام SMOTE، مما يدل على أهمية اختيار طريقة تمثيل البيانات في هذا النوع من التطبيقات. وعند تحليل أداء الصفات بشكل تفصيلي، لوحظ وجود تفاوت في دقة التصنيف بين الصفات الخمس، حيث حققت صفات مثل الود (Agreeableness) والاجتماعية (Extraversion) أداءً أعلى مقارنة ببقية الصفات، بينما كانت صفة العصبية (Neuroticism) الأقل استقراراً في النتائج. ويُفسر هذا التفاوت بأن بعض الصفات تتعكس بشكل أوضح في الخصائص البصرية للكتابة مثل انتظام الخط، التباعد، والانسيابية، في حين أن الصفات ذات الطابع الداخلي غير المباشر تتطلب تمثيلاً أعمق أو بيانات أكثر تنوعاً.

ومن جهة أخرى، لوحظ تقارب في خصائص العينة المدروسة، الأمر الذي انعكس على تمركز معظم النتائج ضمن الفئة المتوسطة للصفات الشخصية، مما ساهم في تقليل التباين بين الفئات وصعوبة التمييز الحاد في بعض الحالات. ومن الناحية التطبيقية، يمكن تحويل هذا العمل إلى نظام عملي على شكل تطبيق هاتف يقوم بتحليل صورة الكتابة اليدوية وإعطاء تقدير أولي لصفات الشخصية، بحيث يُستخدم كأداة مساعدة في مجالات مثل التوجيه الأكاديمي أو التوظيف، وليس كأداة تشخيص نهائي، كما يمكن دمجها في منصات التوظيف لتقديم مؤشرات إضافية عن المتقدمين بطريقة سريعة وغير مباشرة.

وتؤكد هذه النتائج إمكانية توظيف هذا النوع من الأنظمة في تطبيقات مستقبلية ضمن مجالات متعددة كعلم النفس، والتربية، والتوظيف، وعلم الجريمة. ولتحسين الأداء مستقبلاً، يُوصى بتوسيع قاعدة البيانات من حيث الحجم والتنوع اللغوي والثقافي لتعزيز قدرة النماذج على التعميم، إضافة إلى توحيد ظروف جمع البيانات مثل نوع الورق وطريقة التصوير لتقليل التباين في الميزات المستخرجة، إلى جانب دراسة تأثير أنماط الخط المختلفة على دقة النماذج، بما يضمن نتائج أكثر دقة وثباتاً عند تطبيقها على بيانات جديدة.

References:

- [1] S. Hashemi, B. Vaseghi, and F. Torgheh, "Graphology for Farsi handwriting using image processing techniques," IOSR Journal of Electronics and Communication Engineering, vol. 10, no. 3, pp. 01–07, 2015.
- [2] B. Fallah and H. Khotanlou, "Identify human personality parameters based on handwriting using neural network," in 2016 Artificial Intelligence and Robotics (IRANOPEN), pp. 120–126, Apr. 2016, IEEE.
- [3] M. Gavrilescu, "3-layer architecture for determining the personality type from handwriting analysis by combining neural networks and Support Vector Machines," UPB Sci. Bull. Ser. C Electr. Eng. Comput. Sci., vol. 79, no. 4, pp. 135–152, 2017.
- [4] M. Gavrilescu and N. Vizireanu, "Predicting the Big Five personality traits from handwriting," EURASIP Journal on Image and Video Processing, vol. 2018, no. 1, p. 57, 2018.

- [5] V. Bhade and T. Baraskar, "A model for determining personality by analyzing off-line handwriting," in *Advances in Machine Learning and Data Science: Recent Achievements and Research Directives*, pp. 345–354, Springer, 2018.
- [6] D. Sony and R. Sawant, "Identifying human behavior characteristics using handwriting analysis," *Int. Res. J. Eng. Technol.*, vol. 6, no. 04, pp. 4436–4439, 2019.
- [7] M. A. Mostafa, M. Al-Qurishi, and H. I. Mathkour, "Towards personality classification through Arabic handwriting analysis," in *The International Research & Innovation Forum*, pp. 557–565, Springer International Publishing, 2019.
- [8] N. N. Raj, M. Thaha, S. G. Shaji, and S. Shibina, "Forecasting personality based on calligraphy using CNN and MLP," *Int. J. Comput. Sci. Eng.*, vol. 8, no. 7, 2020.
- [9] S. Ghosh, P. Shivakumara, P. Roy, U. Pal, and T. Lu, "Graphology based handwritten character analysis for human behaviour identification," *CAAI Transactions on Intelligence Technology*, vol. 5, no. 1, pp. 55–65, 2020.
- [10] N. Malik and A. Balaji, "Predicting the big-five personality traits from handwriting," in *Innovations in Computational Intelligence and Computer Vision: Proceedings of ICICV 2020*, pp. 225–237, Springer, 2020.
- [11] S. P. Deore, "Human behavior identification based on graphology using artificial neural network," *Acadlore Trans. Mach. Learn.*, vol. 1, no. 2, pp. 101–108, 2022.
- [12] A. Barata, H. Akbar, M. Pilliang, and A. Nasihin, "Graphology analysis for detecting HEXACO personality and character through handwriting images by using convolutional neural networks and particle swarm optimization methods," *Int. J. Ind. Optim.*, vol. 3, no. 2, pp. 110–120, 2022.
- [13] G. Chaubey and S. K. Arjaria, "Personality prediction through handwriting analysis using convolutional neural networks," in *Proc. Int. Conf. Computational Intelligence (ICCI)*, pp. 59–70, Springer, 2021.
- [14] Z. Khan and S. Ambadekar, "A machine learning approach for predicting personality traits," in *Proc. 7th Int. Conf. Computer Applications in Electrical Engineering–Recent Advances (CERA)*, pp. 1–6, IEEE, 2023.
- [15] D. Gagiú and D. Sendrescu, "Detection of personality traits using handwriting and deep learning," *Applied Sciences*, vol. 15, no. 4, p. 2154, 2025.
- [16] L. R. Goldberg, "The development of markers for the Big-Five factor structure," *Psychological Assessment*, vol. 4, no. 1, pp. 26, 1992.
- [17] W. P. Jones, "Enhancing a short measure of big five personality traits with Bayesian scaling," *Educational and Psychological Measurement*, vol. 74, no. 6, pp. 1049–1066, 2014.

- [18] L. R. Goldberg et al., "The international personality item pool and the future of public-domain personality measures," *Journal of Research in Personality*, vol. 40, no. 1, pp. 84–96, 2006.
- [19] L. A. Miller and R. L. Lovler, *Foundations of psychological testing: A practical approach*, Sage Publications, 2018.
- [20] W. K. Mutlag, S. K. Ali, Z. M. Aydam, and B. H. Taher, "Feature extraction methods: a review," *J. Phys.: Conf. Ser.*, vol. 1591, no. 1, pp. 012028, IOP Publishing, 2020.
- [21] K. Simonyan and A. Zisserman, "Very deep convolutional networks for large-scale image recognition," *arXiv:1409.1556*, 2014.
- [22] L. Breiman, "Random forests," *Machine Learning*, vol. 45, pp. 5–32, 2001.
- [23] A. Palomino-Garibay et al., "A Random Forest Approach for Authorship Profiling," [Online]. Available: <http://pan.webis.de>