

## تصميم نظام بالاعتماد على الشبكات العصبونية

### العميقة للتعرف إلى الأرقام الهندية المحررة

#### بخط اليد

طالب الدراسات العليا: علياء عيد كلية: الهمك - جامعة: البعث

الدكتور المشرف: بسيم عمران

#### الملخص

يعد التعرف إلى الأرقام من القضايا المعيارية لخوارزميات التعرف، ويعتبر التعرف إلى الأرقام العربية (الهندية) المحررة بخط اليد من التحديات المهمة في الكثير من التطبيقات ومجالات الحياة، منها الشبكات المصرفية، التطبيقات التجارية،... الخ. تتفاقم مشكلة التعرف إلى الأرقام المحررة بخط اليد بالمقارنة مع مشكلة التعرف إلى الأرقام المطبوعة، بسبب الاختلاف في أشكال وأحجام الأحرف ونمط الكتابة من شخص إلى آخر. بالنظر إلى النقاط السابقة تم في هذا البحث تصميم نظام تعرف جديد باستخدام الشبكات العصبونية العميقة، قادر على التعرف إلى الأرقام المكتوبة بخط اليد باستخدام لغة البرمجة بايثون وبرنامج Pycharm، كما تم تدريبه واختباره باستخدام مجموعة البيانات المعيارية MADbase المكونة من 70000 صورة لأرقام عربية كتبها 700 شخص، قاعدة البيانات مقسمة إلى مجموعة تدريب مكونة من 60.000 صورة ومجموعة اختبار مكونة من 10000. كما تمت مقارنته مع طرق تعرف باستخدام الخوارزميات والشبكات العصبونية المشابهة وخوارزميات التعلم الآلي الكلاسيكية.

**الكلمات المفتاحية:** التعرف إلى الأرقام، التصنيف، الشبكات العصبونية، التعلم العميق، معالجة صورة.

## Design a system based on deep neural networks to recognize handwritten Indian numbers

### Abstract

Recognizing numbers is one of the standard issues for recognition algorithms. Recognizing handwritten Arabic (Indian) numbers is one of the important challenges in many applications and areas of life, including banking, commercial applications, ...etc. The problem of recognizing handwritten numbers is exacerbated compared to the problem of recognizing printed numbers, due to the difference in the shapes and sizes of letters and writing style from one person to another. Considering the previous points, in this research a new recognition system was designed using deep neural networks, capable of recognizing handwritten numbers using the programming language Python and Pycharm program, and it was trained and tested using the MADbase standard data set consisting of 70,000 images of Arabic numerals written by 700 people. the database is divided into a training set of 60,000 images and a test set of 10,000. It has also been compared with methods known using algorithms, similar neural networks, and classic machine learning algorithms.

**Keywords:** Recognize numbers, classification, neural networks, deep learning, image processing.

## 1. مقدمة Introduction

يُطبق التعرف الآلي على نطاق واسع في العديد من جوانب الحياة اليومية، مثل التعرف إلى الوجه والتعرف إلى بصمات الأصابع والتعرف إلى الأرقام، ومع التطور الرقمي أصبحت الطرق الرئيسية للتواصل هي الإنترنت والهواتف المحمولة، حيث تُستخدم الخدمات الرقمية في كل جانب من جوانب حياتنا تقريبًا. بالرغم من ذلك لا تزال هناك بعض الأنشطة والمهام اليومية التي تعتمد على طرق الاتصال التقليدية، مثل استخدام الورقة والقلم. لذلك يمكن أن يوفر التعرف الآلي إلى خط اليد الوقت والجهد بلا شك، ويعد التعرف على الأرقام المكتوبة بخط اليد أحد أكثر التطبيقات نجاحًا في التعرف الآلي على الأنماط حيث تم تنفيذ معظم هذه التطبيقات على أرقام عربية، لأنها أكثر أنظمة الترقيم شهرة في العالم. ومع ذلك تستخدم الأرقام الهندية على نطاق واسع في بعض البلدان في العالم.

يعد التعرف إلى خط اليد أحد أصعب المهام بسبب الاختلافات في نمط وأسلوب الكتابة. نظرًا لأهمية التعرف الآلي إلى خط اليد من كونه نظام ذكي يمكن من خلاله التعرف إلى الأرقام المكتوبة بخط اليد في العديد من التطبيقات مثل التحقق من الشيكات المصرفية، والأعمال التجارية، وقراءة العناوين البريدية، وتطبيقات إدخال البيانات، ... الخ، وتعد هذه أمثلة قليلة<sup>[1]</sup>، فإنه يعد أحد المجالات التي تحظى باهتمام العديد من الباحثين من أجل تطوير خوارزميات وزيادة معدل التعرف، حيث يمثل الإدراك الصحيح للنصوص الرياضية المكتوبة بخط اليد مهمة أكثر صعوبة، وعلى مدار السنوات القليلة الماضية كان التعلم العميق أكثر المجالات التي تم البحث عنها في التعلم الآلي<sup>[2]</sup>.

يركز هذا البحث على جزء التعرف إلى الأرقام الهندية المكتوبة بخط اليد والذي يواجه العديد من التحديات، منها صعوبة كتابة الأرقام الهندية وقواعد البيانات العامة الكبيرة، حيث يوجد دعم قليل جداً لاستخراج الأرقام الهندية من الصور أو المستندات، وعلى

الرغم من أنه يمكن لأدوات التحويل أن تحول الصور إلى تنسيقات أخرى مثل المستند النصي إلا أنها تفشل في حال كانت مكتوبة باللغة الهندية، ويعزى ذلك إلى نمط الكتابة المتصل للأحرف العربية وصعوبة تجزئتها. في هذا البحث تم استخدام الشبكات العصبونية العميقة للتعرف إلى الأرقام الهندية الفردية المكتوبة بخط اليد، ومن خلال عدد مختلف من السيناريوهات والتجارب، تم إثبات أنه يمكن تحقيق معدلات تعرف عالية جداً في هذا النطاق باستخدام تقنيات التعلم الآلي<sup>[2]</sup>.

## 2. هدف البحث Search Goal

يهدف هذا البحث إلى تصميم نظام فعال وذو كفاءة عالية للتعرف إلى الأرقام الهندية الفردية المستخدمة محلياً والمحررة بخط يد، بالاعتماد على تقنيات التعلم الآلي وبالتحديد الشبكات العصبونية العميقة ومعالجة الصورة.

## 3. أهمية البحث Research Importance

يُمكن هذا البحث من قراءة الأرقام الهندية الفردية المحررة بخط يد والمندولة بكثرة في حياتنا اليومية في جداول أو ضمن نصوص بشكل أكثر دقة وبالتالي أقل خطأ، مما يساهم في تعزيز التحول الرقمي في الخدمات اليومية.

## 4. المواد وطرائق البحث Materials and Research Methods

لإنجاز البحث تم استخدام المواد التالية:

1. برنامج PyCharm ومكتباته لكتابة البرامج اللازمة
2. لغة البرمجة python لتصميم النظام المقترح.
3. مجموعة البيانات المعيارية MAD base لتدريب واختبار النموذج المقترح.

## 5. الدراسات المرجعية Reference Studies

قام العديد من الباحثين والمطورين بتطوير أدوات للتعرف على الاحرف الأجنبية والأرقام العربية من المستندات والصور تبعاً للطلب. هذه الأدوات التي تم تطويرها في الأصل لتعمل حصرياً على تعبيرات رياضية مفردة، وربما متعددة الأسطر تم تحديدها مسبقاً في مستند PDF او في صورته، تم توسيعها لتعمل على صفحات كاملة من المستندات عن طريق إضافة دعم لتحليل التخطيط وتقسيم الرياضيات من النص العادي، ولكن بالرغم من التطور والدعم الكبير الا ان الجهود المبذولة تقتصر على أحرف اللغة الأجنبية فقط.

ركز (Sharif et all ; 2019) بهذه الدراسة على التغلب على اثنتين من القيود الرئيسية للأعمال الحالية والتي هي تنوع البيانات وطريقة التعلم الفعالة، ومن ثم تم دمج مجموعات الأرقام العربية الحالية في مجموعة بيانات واحدة وتم زيادتها لإدخال تنوع البيانات. علاوة على ذلك تم اقتراح نموذج عميق جديد لاستغلال عينات البيانات المتنوعة لمجموعة البيانات الموحدة. يستخدم النموذج العميق المقترح ميزات الحافة منخفضة المستوى، يتفوق النموذج المقترح على أحدث أساليب تصنيف الأرقام المكتوبة بخط اليد باللغة العربية ويحصل على دقة تصل إلى 99.59% في مرحلة التحقق<sup>[3]</sup>.

قام (Atsushi et all ; 2019) بتسجيل اختراعه والذي هو عبارة عن نظام لمعالجة الصور القديمة والمشوهة واستخراج البيانات منها وتخزينها في مستند، يتألف هذا النظام من جهاز معالجة المعلومات متصل عبر ناقل النظام بوحدة التحكم، وحدة التشغيل، وحدة قراءة المستندات، وحدة التخزين، وحدة الطباعة. يقوم النظام بتصنيف الصور الى صور تحتوي على صورة فقط او صورة تحتوي على نص فقط او صورة تحتوي على صورة ونص. وفي حال كانت الصورة تحتوي على نص يقوم بمعالجة الصورة لاستخراج بيانات النص وتخزينها في مستند جديد. النظام المصمم يهتم بحارف اللغة الإنكليزية فقط (الاحرف فقط A-Z)، أي انه غير مهني للتعامل مع الحارف الخاصة الحسائية او

المنطقية او التعبيرية بالإضافة الا انه لا يتعامل مع اللغات الأخرى ولا مع الأرقام بكل اللغات<sup>[4]</sup>.

اقترح (Pratik et all ; 2020) البنى القائمة على CNN للتعرف على الأرقام العربية المكتوبة بخط اليد، لقد قمنا أيضاً بتطوير مجموعة بيانات أرقام عربية مكتوبة بخط اليد باستخدام عمليات مورفو المنطقية المختلفة على مجموعة بيانات موجودة وبالتالي زيادة حجم مجموعة البيانات من 3000 إلى 72000 صورة. لقد منح تعديل بنية CNN المقترحة سابقاً دقة قدرها 98.91% وهو ما يمكن مقارنته بأحدث النتائج الموجودة في مجال التعرف على الأرقام العربية المكتوبة بخط اليد<sup>[5]</sup>.

قدم (Shenggu et all ; 2021) نظاماً للتعرف على الأرقام العربية المكتوبة بخط اليد صفر إلى تسعة (0-9) باستخدام نهج الشبكة العصبونية الاحتمالية (PNN)، يمكن لهذا النظام لتعرف على المدخلات المكتوبة بخط اليد والأرقام العربية المستوردة خارجياً في الوقت الفعلي، بما في ذلك عمليتان للمعالجة المسبقة للصور والتعرف عليها. تشارك المعالجة المسبقة للصور التطبيع والتوسع لتكبير خصائص الصورة لسهولة التعرف عليها، تتضمن عملية التعرف حساب مسافة الوضع، والتي يمكن أن تساعد في الحصول على تطابق التشابه بين نموذج المصفوفة ومصفوفة التعلم، وفقاً لمطابقة التشابه سيتم تصنيف مصفوفة ميزة الإدخال إلى أحد الأرقام العشرة. تستخدم هذه الدراسة MATLAB لإنشاء واجهة رسومية سهلة التشغيل، النظام جيد الأداء وقابلية التوسع القوية، والتي أسست منصة تجريبية بسيطة لمزيد من الدراسة المتعمقة للتعرف على الأرقام العربية المكتوبة بخط اليد<sup>[6]</sup>.

## 6. الأرقام الهندية والتعرف عليها

## Indian Numbers and Recognition

نظام العد الهندي هو نظام عد عشري ويتمثل في الأرقام الهندية ويستخدمها العرب الآن، وترجع أصوله إلى القرن التاسع الميلادي والأرقام العربية التي نستخدمها هي (١، ٢، ٣، ٤، ٥، ٦، ٧، ٨، ٩) حيث يتم التحدث باللغة العربية في جميع أنحاء العالم العربي وهي خامس أكثر اللغات شعبية في العالم تعد اللغة العربية واحدة من اللغات الرئيسية في العالم. يتم التحدث بها في مناطق عديدة بما في ذلك شمال إفريقيا ومعظم شبه الجزيرة العربية وأجزاء أخرى من الشرق الأوسط. يتحدث حوالي 500 مليون شخص بهذه اللغة العربية هي اللغة الرسمية لحوالي 24 دولة مثل سوريا والجزائر والبحرين ومصر وغيرها وكذلك اللغة الوطنية لمالي والسنغال والصومال وأكثر من ذلك هي لغة الإسلام ، على الرغم من وجود بعض البرامج المتاحة تجاريًا، خاصة للتعرف على الأحرف المطبوعة لبعض اللغات، إلا أن النجاح لم يمتد بعد إلى الأحرف المكتوبة بخط اليد، يمكن لتقنية التعرف على الأرقام العربية المكتوبة بخط اليد أن تساهم بشكل كبير في تطوير نظام التعرف الضوئي على الحروف الكامل، لذلك لا يزال التعرف الضوئي على الأرقام المكتوبة بخط اليد مجالاً نشطاً للبحث، تم تنفيذ معظم الأعمال السابقة المتعلقة بالتعرف الضوئي على الحروف للنص العربي باستخدام الأحرف المطبوعة [7].

يوضح الشكل (1) عينات من الأرقام العربية (الهندية) من 0 إلى 9.



الشكل (1) الأرقام الهندية من 0 إلى 9

## 7. التعلم العميق deep learning

تتكون نماذج التعلم العميق من شبكات عميقة متنوعة منها خاضع للإشراف مثل الشبكات العصبونية العميقة DNNS وشبكات موجزة عميقة DBNs والشبكات العصبونية الانتقافية CNNs والشبكات العصبونية التكرارية RNNs ومنها غير خاضع للإشراف مثل المشفرات التلقائية Auto encoder وآلات بولتزمان المقيدة RBMs. تتعلم نماذج التعلم العميق مباشرة تمثيلات الميزات من البيانات الأصلية مثل الصور والنصوص دون الحاجة إلى هندسة الميزات اليدوية. وبالتالي يمكن تنفيذ طرق التعلم الآلي بطريقة شاملة. وبالنسبة لمجموعة البيانات الكبيرة تتمتع أساليب التعلم العميق بميزة كبيرة في التعامل معها [4]. يعرض الجدول (1) مقارنة بين خوارزميات التعلم العميق المختلفة.

### 7.1 بارامترات تقييم البحث

يوجد مجموعة من البارامترات لتقييم البحث، إلا أن معظم الأبحاث اعتمدت على بارامتر الدقة Accuracy والذي يعبر عن نسبة عدد الأرقام التي تم التعرف إليها بشكل صحيح إلى قاعدة الاختبار بأكملها، والذي بحسب من العلاقة التالية:

$$Accuracy = \frac{TP}{TP + FP}$$

حيث أن:

TP : يشير إلى عدد الأرقام التي تم التعرف إليها بشكل صحيح.

FP: يشير إلى عدد الأرقام التي تم التعرف إليها بشكل خاطئ.



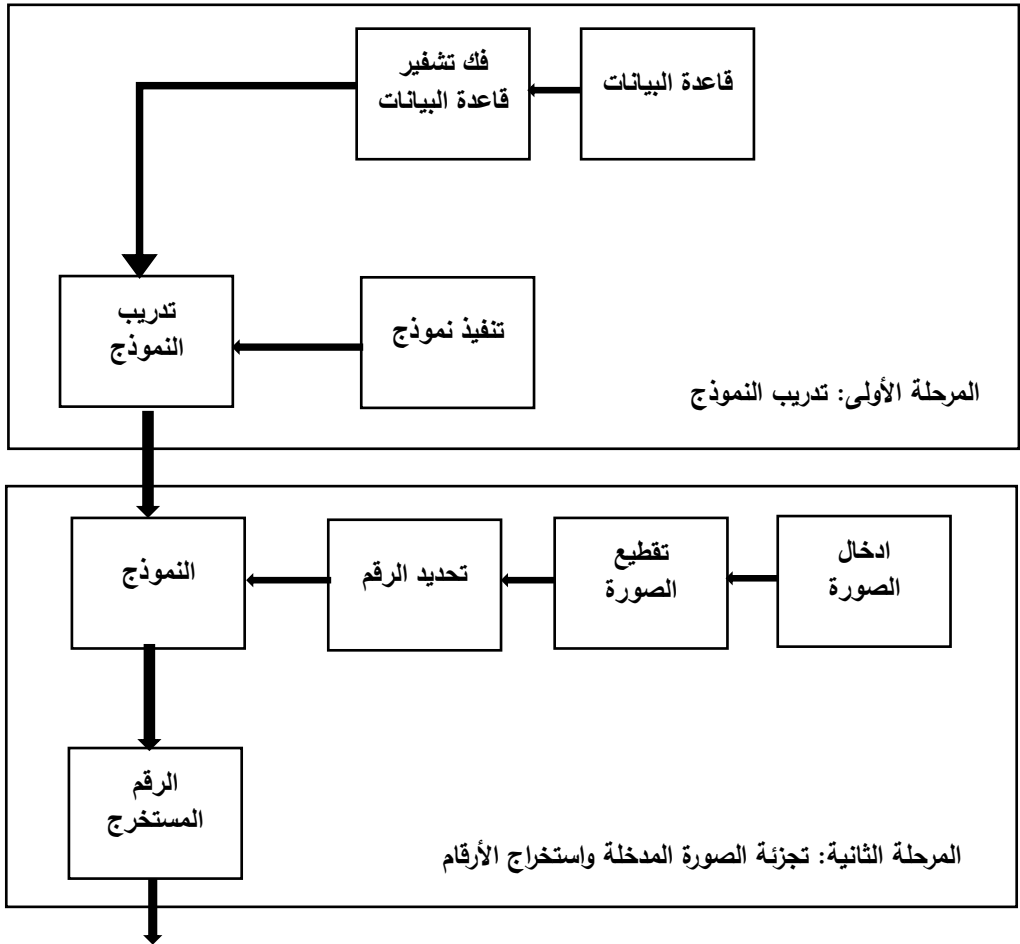
## جدول (1) مقارنة بين خوارزميات التعلم العميق.

المهام	خاضع للإشراف أو غير خاضع للإشراف	أنواع البيانات المناسبة	الخوارزميات
استخراج الميزة خاصية التخفيض تقليل الضجيج	غير خاضع للإشراف	البيانات الخام شعاع الميزات	Auto encoder
استخراج الميزة خاصية التخفيض تقليل الضجيج	غير خاضع للإشراف	شعاع الميزات	RBM
استخراج الميزة التصنيف	خاضع للإشراف	شعاع الميزات	DBN
استخراج الميزة التصنيف	خاضع للإشراف	شعاع الميزات	DNN
استخراج الميزة التصنيف	خاضع للإشراف	البيانات الخام شعاع الميزات المصفوفات	CNN
استخراج الميزة التصنيف	خاضع للإشراف	البيانات الخام شعاع الميزات	RNN

## 8. تصميم نظام التعرف الى الأرقام الهندية

### Indian Numeral Recognition System Design

يتكون النظام المقترح بشكل رئيسي من مرحلتين، المرحلة الأولى تهتم بمعالجة قاعدة البيانات وتصميم نموذج التعلم العميق وتدريبه، بينما تهتم المرحلة الثانية بمعالجة الصورة المدخلة واستخراج الرقم الموجود ضمن الصورة واختبار النموذج المصمم مسبقاً كما يوضح الشكل (2).




الشكل (2) المخطط الصندوقي للنظام المقترح.

### 8.1. قاعدة البيانات المستخدمة Database Used

قاعدة بيانات المستخدمة في هذا البحث هي MADBase وهي نسخة معدلة من ADBase والتي لها نفس تنسيق معيار MNIST. يتكون كل من ADBase و MADBase من 70000 رقم كتبها 700 كاتب. كتب كل كاتب كل رقم (من 0 إلى 9) عشر مرات، وذلك لضمان تضمين أساليب الكتابة المختلفة.

تم جمع قاعدة البيانات من مؤسسات مختلفة: كليات الهندسة والقانون، وكلية الطب، والجامعة المفتوحة (التي يمتد طلابها إلى مجموعة واسعة من الأعمار)، ومدرسة ثانوية، ومؤسسة حكومية، يتم تقسيم قواعد البيانات إلى مجموعتين: مجموعة تدريب (60.000 رقم إلى 6000 صورة لكل رقم) ومجموعة اختبار (10000 رقم إلى 1000 صورة لكل رقم). يعرض الشكل عينات من صور التدريب والاختبار لقاعدة بيانات MADBase.



الشكل (3) عينات من صور التدريب والاختبار لقاعدة البيانات MADBase

## 8.2. تصميم نموذج التصنيف Classification Model Design

اقترح الباحث في هذا البحث تصميم نظام تصنيف للأرقام الهندية، يتكون من شبكة عصبونية عميقة مدمجة مع منظومة معالجة أولية للصورة واستخراج السمات منها، بحيث يمكن للنظام المقترح استقبال الصور بشكل مباشر.

الشبكة العصبونية العميقة المقترحة تتكون من ثلاث طبقات، الطبقتين الأولى والثانية تحتوي كل منهما على 100 عصبون، أما الطبقة الثالثة الأخيرة فهي طبقة الخرج والتي تحتوي على 10 عصبونات. أما منظومة المعالجة الأولية للصورة واستخراج السمات فتتكون من 5 طبقات، طبقتين لتطبيق المرشحات وطبقتين لاختزال المصفوفات وطبقة تسطيح. ونظراً للحجم الكبير للبنية المقترحة فلا يمكن وضع مخطط توضيحي لها حيث يتم بناء طبقة الدخل من خلال طبقة Conv2D وهي الطبقة التي يمكن من خلالها بناء الشبكة العصبونية العميقة:

```
model.add(Conv2D(32, (3, 3), activation='relu',  
kernel_initializer='he_uniform', input_shape=(img_rows, img_cols,  
1)))
```

أي أنه يتم تطبيق 32 مرشح بحجم (3\*3) على الصورة المدخلة، وبخطوة افتراضية (1,1) وبحشو افتراضي valid ، وبشكل أبعاد الصورة الافتراضي أي أن عدد القنوات اللونية للصور يتم تمثيلها في البعد الأخير، و دالة التنشيط 'relu' وهي اختصار لـ (Rectified Linear Unit) هي من أشهر دوال التنشيط المستخدمة وتتكون من دالتين خطيتين و مع بعضهما تكونان الدالة غير الخطية:

$$\begin{cases} 0 & \text{if } x \leq 0 \\ x & \text{if } x > 0 \end{cases}$$

نوع التهيئة التي سيتم فيها تهيئة المرشح هو 'he\_uniform'. وأخيراً لتحديد حجم الصور التي سيتم تقديمها وهو (1,32,32). خرج هذه الطبقة يتم حسابه بالاعتماد على المعادلات التالية:

$$\text{new\_col}=(\text{col}-2*\text{p}+\text{f})/\text{strides} + 1$$

$$\text{new\_row}=(\text{row}-2*\text{p}+\text{f})/\text{strides} + 1$$

$$\text{new\_col}=\text{new\_row}=32-3+1=30$$

يُمرر خرج طبقة Conv2D الى طبقة MaxPooling والتي تستخدم لاختزال أبعاد المصفوفة من (30 \* 30) الى (15\*15)، والسبب الأول لأستخدام هذه الطبقة هو أنها تقوم بتخفيف العبء الحسابي. والسبب الثاني هو الضبط الزائد "Reducing overfitting" فهي تساعد في الحد من الضبط الزائد، من خلال التركيز على البكسلات الأعلى قيمة وتتجاهل البكسلات الأقل قيمة، وبالتالي تكون تعليمة اضافة طبقة MaxPooling2D بحجم نافذه (2,2) هي:

$$\text{model.add(MaxPooling2D((2, 2)))}$$

ومن ثم يتم تطبيق 64 مرشح على خرج الطبقة السابقة بحجم (3\*3) وبخطوة افتراضية (1,1) وبحشو افتراضي valid ، وبشكل أبعاد الصورة الافتراضي أي أن عدد القنوات اللونية للصور يتم تمثيلها في البعد الأخير، و دالة التنشيط 'relu'، ونوع التهيئة التي سيتم فيها تهيئة المرشح هو 'he\_uniform'. خرج هذه الطبقة يتم حسابه بالاعتماد على المعادلات المذكورة سابقا كما يلي:

$$\text{new\_col}=\text{new\_row}=15-3+1=13$$

وعدد المرشحات يصبح عدد القنوات ويساوي الى 64، وتكون التعليمة كالتالي:

$$\text{model.add(Conv2D(64, (3, 3), activation='relu', kernel_initializer='he_uniform'))}$$

ومن ثم يتم اختزال ابعاد المصفوفة الى (6\*6) بإضافة طبقة MaxPooling2D وبحجم نافذه (2,2) كما يلي:

```
model.add(MaxPooling2D((2, 2)))
```

خرج الطبقة MaxPooling2D هو (6, 6, 64) لإدخال البيانات الى طبقة Dense يجب أن تكون البيانات ثنائية البعد لذلك نحتاج الى إضافة طبقة التسطيح flatten في البداية ومن ثم اضافة طبقة Dense والتي هي مجرد طبقة مكونة من وحدات منتظمة نسميها العصبونات. يتلقى كل عصبون مدخلات من جميع الخلايا السابقة، وبالتالي نقول عنها "متصلة بكثافة" أو "Densely Connected". ويكون خرج الطبقة مساوياً الى عدد العصبونات في الطبقة، وبالتالي لإضافة طبقات خفية الى الشبكة نستخدم التعليمات التالية:

```
model.add(Flatten())
```

```
model.add(Dense(100, activation='relu',
```

```
kernel_initializer='he_uniform'))
```

```
model.add(Dense(100, activation='relu',
```

```
kernel_initializer='he_uniform'))
```

طبقة الخرج عبارة عن طبقة Dense مكونه من 10 عصبونات حيث كل عصبون يقابل رقم ضمن المجال [0-9] ، ولكل عصبون تابع التنشيط softmax وهي دالة رياضية مدخلاتها شعاع من الأعداد، وخرجها شعاع من القيم الاحتمالية، أي تقوم بتحويل متجه الأعداد إلى متجه احتمالي، حيث تتناسب احتمالات كل قيمة مع المقياس النسبي لكل قيمة في المتجه. وتستخدم لمهام التصنيف

المتعدد ولها الشكل التالي:

$$\text{Softmax}(x_i) = \frac{\exp(x_i)}{\sum_j \exp(x_j)}$$

بذلك تكون تعليمة إضافة طبقة الخرج للشبكة هي:

```
model.add(Dense(10, activation='softmax'))
```

يوضح الشكل (4) بنية الشبكة المصممة، كما يوضح الجدول (2) ملخص لبيانات الشبكة المصممة.

طبقة الدخل وتطبيق المرشحات (الصورة)	Conv2D 32 (3,3)
	'relu'
طبقة خفية لاخترال المصفوفة	MaxPooling (2,2)
طبقة خفية لتطبيق المرشحات	Conv2D 64 (3,3)
	'relu'
طبقة لاخترال المصفوفة	MaxPooling (2,2)
طبقة التسطيح	Flatten
طبقة خفية تحتوي 100 عصبون	Dense (100)
	'relu'
طبقة خفية تحتوي 100 عصبون	Dense (100)
	'relu'
طبقة الخرج	Dense (10)
	Softmax

الشكل (4) بنية الشبكة العصبونية العميقة المصممة

جدول (2) بيانات الشبكة المصممة

Layer (type)	Output Shape	Param #
conv2d (Conv2D)	(None, 30, 30, 32)	320
max_pooling2d (MaxPooling2D)	(None, 15, 15, 32)	0
conv2d_1 (Conv2D)	(None, 13, 13, 64)	18496
max_pooling2d_1 (MaxPooling2)	(None, 6, 6, 64)	0
flatten (Flatten)	(None, 2304)	0
dense (Dense)	(None, 100)	230500
dense_1 (Dense)	(None, 100)	10100
dense_2 (Dense)	(None, 10)	1010

Total params: 260,426


Trainable params: 260,426

Non-trainable params: 0




### 8.3. تدريب النموذج Model Training

يوضح الشكل (5) دقة التدريب ودقة التحقق خلال تدريب الشبكة على أول 20 زوج من البيانات، من الجدير بالذكر انه تم تدريب النموذج على 100 زوج من البيانات تم تطبيقهم على خمس مراحل كل مرحلة تضم 20 زوج. يوضح الشكل (6) معدل الخسارة للاختبار والتحقق خلال أول 20 زوج من البيانات أثناء تدريب الشبكة.



الشكل (5) دقة الاختبار والتحقق



الشكل (6) معدل الخسارة للاختبار والتحقق

#### 8.4. نتائج التنفيذ Implementation Results

إن عينات التدريب مقسمه الى 6000 صورة لكل رقم لتشكل في النهاية مجموعة التدريب المكونة من 60000 صورة للأرقام العشرة ، كما تتألف مجموعة الاختبار من 1000 صورة لكل رقم لتشكل مجموعة الاختبار المكونة من 10000 صورة.

يوضح الشكل (7) مصفوفة الارتباك المعبرة عن دقة تدريب النموذج لكل رقم من الأرقام، تعبر مصفوفة الارتباك عن عدد مرات التعرف الصحيحة والخاطئة لكل عدد من الاعداد. يوضح الشكل (8) مصفوفة الارتباك المعبرة عن دقة تحقق النموذج لكل رقم من الأرقام.

	0	1	2	3	4	5	6	7	8	9	Acc
0	5976	13	0	0	0	9	2	0	0	0	99.6%
1	6	5979	0	0	0	0	5	0	0	10	99.65%
2	8	7	5964	0	0	5	8	2	0	0	99.4%
3	0	12	0	5981	0	0	7	0	0	0	99.68%
4	8	0	14	0	5974	0	4	0	0	0	99.56%
5	13	9	0	0	0	5976	2	0	0	0	99.6%
6	1	9	2	3	2	0	5982	0	0	1	99.7%
7	0	5	0	0	3	0	2	5986	4	0	99.76%
8	0	6	0	0	0	0	6	4	5981	3	99.68%
9	7	7	0	0	0	3	7	0	0	5976	99.6%

الشكل (7) مصفوفة الارتباك لدقة التدريب

	0	1	2	3	4	5	6	7	8	9	Acc
0	995	3	0	0	0	1	1	0	0	0	99.5 %
1	3	993	0	0	0	0	2	0	0	2	99.3%
2	1	2	994	0	0	2	1	0	0	0	99.4%
3	0	3	0	996	0	0	1	0	0	0	99.6%
4	1	0	3	0	995	0	0	0	1	0	99.5%
5	2	3	0	0	0	992	1	0	1	1	99.2%
6	0	2	0	0	1	0	996	0	0	1	99.6%
7	0	1	1	0	1	0	1	993	2	1	99.3%
8	1	2	0	0	1	0	2	1	991	2	99.1
9	1	3	0	0	0	1	1	0	0	994	99.4%

الشكل (8) مصفوفة الارتباك لدقة التحقق

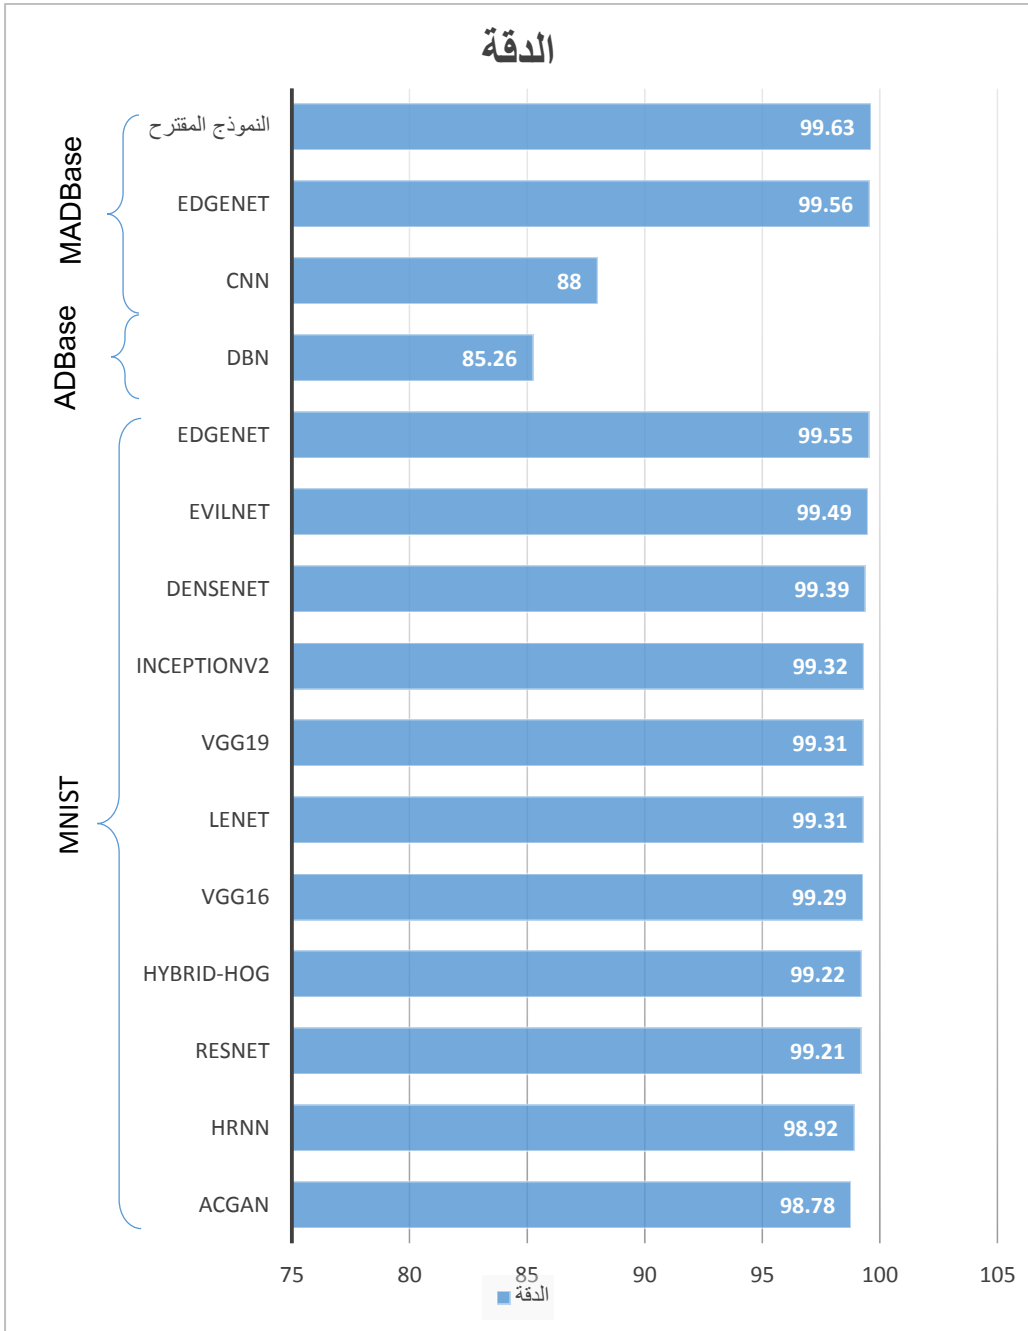
### 8.5. مقارنة النتائج Compare Results

النموذج المقترح تم تدريبه واختباره على قاعدة البيانات MADBase ، وبما أن قاعدة MADBase لها نفس تنسيق قاعدة MNIST لذلك سيتم مقارنة نتائج تنفيذ النموذج المقترح مع النماذج والخوارزميات المطبقة على كلتا القاعدتين كما يوضح الجدول (3) والشكل (9).

جدول (3) مقارنة دقة التعرف للدراسات مع النموذج المقترح

بنية الشبكة	قاعدة البيانات	دقة التعرف (%)
ACGAN	MNIST	98.78
HRNN		98.92
ResNet		99.21
Hybrid-HOG		99.22
VGG16		99.29
LeNet		99.31
VGG19		99.31
InceptionV2		99.32
Densenet		99.39
EvilNet		99.49
EdgeNet		99.55
DBN	ADBase	85.26
CNN	MADBase	88
EdgeNet		99.56
النموذج المقترح		99.63

الشكل (9) مقارنة دقة التعرف للدراسات مع النموذج المقترح.



نلاحظ من مقارنة النتائج السابقة تفوق النموذج المقترح على النماذج السابقة بالنسبة للنماذج المصممة على كل من قاعدة البيانات MNIST و ADBase و MADBase، يعزى هذا التفوق إلى بنية الشبكة المصممة حيث يتم تطبيق عدد من المرشحات على مرحلتين، كما يتم تخفيف العبء الحسابي على الشبكة المصممة على مرحلتين أيضاً، مما يعطي قابلية تعلم أكثر كفاءة للشبكة المصممة. كما يلاحظ من مصفوفة الارتباك أن نسبة الخطأ تأتي بشكل أساسي من الالتباس بين كل من الرقم 0 والرقم 5، الرقم 7 والرقم 1، الرقم 8 والرقم 1.

## 9. الاستنتاجات والتوصيات Conclusions and Recommendations

أثبتت الشبكات العصبونية العميقة كفاءتها في مجال التعرف على الأرقام الهندية المحررة بخط اليد، وكون هذه القضية تعد معيار أساسي للمقارنة بين خوارزميات التعرف والتصنيف، فإن الشبكات العصبونية العميقة من أكثر التقنيات والخوارزميات كفاءة في مجال التعرف، ويمكن زيادة دقة التعرف من خلال إضافة مرحلة إضافية تعمل كمعالجة مسبقة للصور، كما يمكن تطوير النموذج للتعرف على الأرقام الطويلة.

## 10. المراجع Reference

1. Mahmoud, S. (2008). Recognition of writer-independent off-line handwritten Arabic (Indian) numerals using hidden Markov models. *Signal Processing*, 88(4), 844–857.
2. LeCun, Y., Bengio, Y., & Hinton, G. (2015). Deep learning. *nature*, 521(7553), 436–444
3. Sharif, S. M. A., Mujtaba, G., & Uddin, S. M. (2019). EdgeNet: A novel approach for Arabic numeral classification. *arXiv preprint arXiv:1908.02254*.
4. Liu, H., Lang, B. 2019 – Machine Learning and Deep Learning Methods for Intrusion Detection Systems: A Survey, Applied Sciences , VOL.9(20), PP.4396
5. Ahamed, P., Kundu, S., Khan, T., Bhateja, V., Sarkar, R., & Mollah, A. F. (2020). Handwritten Arabic numerals recognition using convolutional neural network. *Journal of Ambient Intelligence and Humanized Computing*, 11(11), 5445–5457.

6. Tang, Y., Zhang, S., & Niu, L. (2021). Handwritten Arabic numerals recognition system using probabilistic neural networks. In Journal of Physics: Conference Series (Vol. 1738, No. 1, p. 012082). IOP Publishing.
7. Sawy,A . Bakry,H . and Loey,M. 2016."CNN for Handwritten Arabic Digits Recognition Based on LeNet-5"
8. AlKhateeb,J. and Alseid,M.2014."DBN -Based learning for Arabic handwritten digit recognition using DCT features,"