

الجمهورية الجزائرية الديمقراطية الشعبية
وزارة التعليم العالي و البحث العلمي



جامعة الشهيد حمه لخضر - الوادي
كلية العلوم الدقيقة
قسم نظم المعلوماتية



عد الكائنات في الصورة باستخدام التعلم الآلي
والشبكات العصبية

مذكرة تخرج مقدمة لنيل شهادة ليسانس

تحت اشراف :

قية سناء السحر

إعداد الطالبات :

- نعمي كلثوم
- طلحة عويشة
- تجيني شيراز

لجنة المناقشة:

1- خلايفة عبدالناصر

2- كيرتو اسماعيل

السنة الجامعية: 2022/2021

Abstract

Computer vision is a field of artificial intelligence (AI) that enables computers and systems to derive meaningful information from digital images, videos and other visual inputs and take actions or make recommendations based on that information.

In this report, we use machine learning and neural networks to teach computers to count objects in the image, in this context, we present both a machine learning classification using support vector machine algorithm and deep learning method for counting objects in an image and we use the example of counting grains of wheat in images of wheat plants, the number returned is actually an estimation.

.

KEYWORDS:

SVM Classification, Object Counting, Machine Learning, Deep Learning

الرؤية الحاسوبية هي أحد مجالات الذكاء الاصطناعي (Artificial Intelligence) التي تمكن أجهزة الكمبيوتر من فهم محتوى الصور باستخلاص بعض المعلومات منها واتخاذ الإجراءات اللازمة أو تقديم توصيات بناءً على تلك المعلومات.

في هذا التقرير ، نستخدم التعلم الآلي والشبكات العصبية لتعليم أجهزة الكمبيوتر عد الكائنات في الصور ، وفي هذا السياق ، نقدم تصنيفاً للتعلم الآلي (Machine Learning) باستخدام خوارزمية المتجه الداعم (Support Vector Machine) وطريقة التعلم العميق (Deep Learning) لعد الكائنات في صورة ما ونستخدم مثال على ذلك عد حبات القمح في صور نباتات القمح.

الكلمات المفتاحية:

التعلم الآلي , تصنيف بالطريقة SVM , عد الكائنات، التعلم العميق .

شكر وتقدير

الحمد والشكر لله أولو دنما وزيد الذي أعاننا على إكمال مذكرتنا

وتقدم بخالص الشكر والعرفان لى كل من ساهم في مدنا بالمعلومات وسهل من جمعها واستاؤتنا

الكريمة " قيه سناء السحر " التي ساعتنا من خلال الملاحظات المهمة والدقيقة وجميع

الانتقادات التي أثرت بالشكل الإيجابي على سير عمل المذكرة

الأهداء

كم تخوننا الكلمات والتعابير فتاتي متعثرة ترتدي برد الحب ووشاح الحياء وأي الكلمات تسعفني وأي التعابير تنجدني وأنا أتحدث من أحبي مصابيح كانت تدير سبيلي أهتدي بها في ظلمات الطريق فتغدو الحياة كلها أمان، وليس لي ثمين أهديه خير من ثمرة نجاحي وذروة جدي وكدي بأسمى عبارات الشكر والعرفان أهدي هذا العمل المتواضع إلى زهرتي حياتي أمي الغالية* دليلة* وأبي العزيز* الطاهر* وجدتي العزيزة* عويشة*

وأقول لهما إن قلت شكراً فشكري لن يوفيكُم، حقاً سعيتُم فكان السعي مشكوراً،

إن جفّ حبري عن التعبير يكتبكم قلب به صفاء الحب تعبيراً.

كما أهدي هذا المولود العلمي إلى أخوتي الأعزاء* ياسين وأيمن وعادل وخوخة وصونيا وسميرة ووداد وزوجة أبي

أسماء.*

إلى أستاذي* شطي الدراجي* وأصدقائي قريبتهم وبعيدهم

ولا أنسى أبناء أختي* أرام وأبرار* وأبناء أخي* الطاهر الصغير وقينو*

دمتم لي سنداً

طلحة عويشة

الاهداء

الحمد لله والصلاة على الحبيب المصطفى واهله ومن وفى اما بعد:
الحمد لله الذي وفقنا لتثمين هذه الخطوة في مسيرتنا الدراسية
بمذكرتنا هذه ثمرة الجهد و النجاح بفضلته تعالى مهداة الى الوالدين
الكريمين حفظهما الله و ادامهما نورا لدربي
لكل العائلة الكريمة التي ساندتني ولا تزال من اخوة و اخوات الى
رفيقات المشوار الاتي قاسموني لحظات رعاهم الله ووفقهم
الى كل من كان لهم اثر على حياتي والى كل من احبهم قلبي و نسيهم
قلمي .

نعمى كلثوم

الاهداء

إلى كل من علمني حرفا في هذه الدنيا

إلى روح أبي الزكية الطاهرة

إلى روح أُمي العزيزة الغالية التي ترمت من أجلي

إلى زوجي قرة عيني و أبنتي مؤنستي

إلى جميع أفراد الأسرة التربوية في الجزائر الحرة الأبية

إلى كل هؤلاء و هؤلاء أهدي هذا العمل المتواضع ،ونسئل الله الله أن يجعله

نبراسا لكل علم

في الأخير أود الترحم على الروح الطاهرة النبيلة الصحفية الفلسطينية شرين

أبو عاقلة

تجيني شيراز

الفهرس

V.....	ملخص
IV.....	شكر و تقدير
VI.....	الفهرس
V.....	مقدمة عامة
Error! Bookmark not defined.	المقدمة :

الفصل الأول : مفاهيم عامة حول معالجة الصورة الرقمية

3.....	1.1. المقدمة :
3.....	2.1 معالجة بيانات الصورة Image Processing
3.....	1.2.1 رؤية منخفضة المستوى Low Level Vision :
3.....	2.2.1 رؤية متوسطة المستوى Mid-Level Vision :
4.....	3.2.1 رؤية عالية المستوى High Level Vision :
4.....	3.1 Counting Objects (العد الكائن) :
4.....	1.3.1 مفهوم العد :
4.....	4.1 طرق العد :
4.....	1.4.1 العد عن طريق الكشف Count By Detection :
4.....	2.4.1 العد عن طريق الانحدار Count By Regression :
4.....	3.4.1 العد عن طريق التجزئة Count By Segmentation :
5.....	5.1 أمثلة عن عد الكائنات الموجودة في الصورة.
6.....	La traduction est trop longue pour
6.....	1.6.1 عد المنتج ورقابة الجودة Quality Control :
6.....	2.6.1 حركة المرور Traffic Flow :
6.....	3.6.1 عد الخلايا Counting Cells :

7.1. الخلاصة:	7
---------------	---

الفصل الثاني: التعلم الآلي والتعلم العميق

1.2. المقدمة	9
2.2. الذكاء الاصطناعي (Intelligence Artificielle) :	9
3.2. تعليم الآلة (Machine Learning) :	10
1.3.2. تعلم الآلة الخاضع للإشراف Supervised Machine Learning:	10
2.3.2. التعلم الآلي غير الخاضع للإشراف Unsupervised Machine Learning:	11
3.3.2. تعزيز التعلم Reinforcement Learning:	11
4.2. تعريف خوارزمية آلة المتجه الداعم SVM :	11
1.4.2. استخدامات SVM (خوارزمية آلة المتجه الداعم):	12
2.4.2. المستوى الفائق Hyperplane:	12
3.4.2. المستوى الهامش Margin Level :	13
5.2. التعلم العميق Deep Learning:	13
1.5.2. الشبكات العصبية الاصطناعية Artificial Neural Network ANN	14
2.5.2. الشبكات العصبية الملتفة Convolutional Neural Network CNN	14
3.5.2. عملية التعلم العميق Deep learning Process	16
6.2. تقنيات التعلم العميق مقابل التعلم الآلي	16
يقارن الجدول التالي بين تقنيتي التعلم الآلي و التعلم العميق	16

الفصل الثالث : التصميم و التنفيذ

1.3. المقدمة	19
2.3. لغة برمجة المستخدمة The Programming Language Used :	19
الشكل 09 : لغة البايثون	19
3.3. بيئة التطوير:	19
1-3-3: VISUAL STUDIO	19
2-3-3: JUPYTER	20
4.3. المكتبات المستخدمة :	20

20	 : Machine Learning تعلم الآلة
22	: Deep Learning التعلم العميق
22	: 5.3. المنهجية المتبعة
23	: 6.3. تحضير بيانات التدريب
23	 الشكل 3-03 : المكتبات المستخدمة (تحضير البيانات)
23	: 1.6.3. تحميل صورة بتدرج رمادي
24	: 2.6.3. تجزئة الصورة
25	: 3.6.3. تصنيف البيانات
27	 : Deep Learning استخدام التعلم العميق
29	: 8.3. الخلاصة
31	خاتمة عامة
32	قائمة المراجع

قائمة الاشكال:

5	الشكل 01: مثال عن عد الكائنات في الصور
6	الشكل 02 : عد الخلايا البكتيرية ، عد الحشود في أنظمة المراقبة
10	الشكل 03 : مجالات الذكاء الاصطناعي
12	الشكل 04 : المستوى الفائق
13	الشكل 05 : المستوى الهامش
14	الشكل 06 : الشبكات العصبية الاصطناعية
15	الشكل 07 : الشبكة العصبية الالتفافية
16	الشكل 08 : عملية التعلم العميق
19	الشكل 09 : لغة البايثون
20	الشكل 10 : Visual Studio
20	الشكل 11 : Jupyter
23	الشكل 12 : ملخص عمل البرنامج
24	الشكل 13 : صورة ملونة
24	الشكل 14 صورة بتدرج الرمادي
25	الشكل 15 : صور جزئية

قائمة الاشكال الخاصة بجزء البرمجي :

21	الشكل 3-01 : المكتبات المستخدمة (تعلم الآلة)
22	الشكل 3-02 : المكتبات المستخدمة (تعلم العميق)
23	الشكل 3-03 : المكتبات المستخدمة (تحضير البيانات)
23	الشكل 3-04 : قراءة صورة
24	الشكل 3-05 : حفظ الصور
25	الشكل 3-06 : تحميل البيانات (تعلم الآلة)
26	الشكل 3-07 : تجزئة البيانات
26	الشكل 3-08 : تغيير الأبعاد
26	الشكل 3-09 : تدريب - تنبؤ
26	الشكل 3-10 : نسبة الدقة
27	الشكل 3-11 حفظ النموذج
27	الشكل 3-12 : استدعاء النموذج
27	الشكل 3-13 : اختبار صورة جديدة
28	الشكل 3-15 تعريف طبقات النموذج
28	الشكل 3-17 : نتائج التدريب

مقدمة عامة

المقدمة:

يهتم مجال معالجة الصور بتطوير و استخدام آليات و خوارزميات المعالجة الرقمية , يعتبر هذا المجال أحد اللبئات و الركائز الأساسية في رؤية الحاسب , حيث تتم المعالجات الأولية كتحسين الصورة أو اقتصاص الأجزاء في العمليات اللاحقة كالتعرف على الأشياء الموجودة في الصورة أو قياس الأحجام أو عد الكائنات .

الذكاء الاصطناعي هو تقنية تمكّن الآلة من محاكاة السلوك البشري ، والتعلم الآلي هو تقنية لتحقيق الذكاء الاصطناعي من خلال الخوارزميات المدربة بالبيانات ، أما التعلم العميق فيعتبر نوعاً من التعلم الآلي المستوحى من بنية الدماغ البشري حيث يسمى هذا الهيكل بالشبكة العصبية الاصطناعية

باستخدام تقنيات التعلم الآلي والتعلم العميق ، يمكننا إنشاء أنظمة كمبيوتر وتطبيقات تقوم بمهام ترتبط عادة بالذكاء البشري. تتضمن هذه المهام التعرف على الصور والتعرف على الكلام وترجمة اللغات.

وفي هذا التقرير درسنا إمكانية استخدام التعلم الآلي والشبكات العصبية لعد الكائنات في الصورة الرقمية واعتمدنا مثال عد حبات القمح في صور تحتوي على نباتات وسنابل القمح.

ولقد قمنا بتنظيم تقريرنا على النحو التالي:

الفصل الأول: تخصص الفصل الأول في وصف بعض مفاهيم معالجة الصور الرقمية (معالجة بيانات

الصورة، عد الكائنات طرق العد, تطبيقات عد كائنات).

الفصل الثاني: في هذا الفصل نقدم خوارزمية التعلم الآلي المتبعة في عد كائنات الصورة بالإضافة إلى تعريف مفهوم الشبكات العصبية.

الفصل الثالث: في هذا الفصل نقدم المنهجية المتبعة لعد حبات القمح في الصورة وطرق خطوات تنفيذها

الفصل الاول

مفاهيم عامة حول معالجة الصورة الرقمية

General concepts about digital image processing

الفصل الأول : مفاهيم عامة حول معالجة الصورة الرقمية

1.1. المقدمة :

تتمثل الرؤية الحاسوبية [11] في شكل من أشكال الذكاء الاصطناعي ، حيث ان هذه التقنية تساعد على رؤية العالم وتحليل البيانات المرئية بالإضافة إلى تحديد ومعالجة الأشياء مثل الصور ومقاطع الفيديو... الخ

في الفصل الأول نتطرق إلى تقنيات مختلفة لمعالجة الصورة مع توضيحات لمفهوم وطرق عد الكائنات في الصورة

2.1 معالجة بيانات الصورة Image Processing

وهي تتمثل في تركيز التشفير الرقمي المناسب للصورة وإيجاد طرائق معالجة هذه البيانات الرقمية حيث يهتم مجال معالجة الصور بتطوير واستخدام آليات وخوارزميات لمعالجة الصور الرقمية [6] ، وتتنوع أهداف معالجة الصور بشكل كبير وتتمثل معالجة الصورة في (3) مستويات [5] هي :

1.2.1. رؤية منخفضة المستوى Low Level Vision :

تهتم معالجة الصورة ذات المستوى المنخفض بشكل أساسي باستخراج الأوصاف من الصورة و تتضمن عملية المعالجة منخفضة المستوى مهام مثل المعالجة المسبقة للصور لتقليل الضوضاء وتحسين التباين وما إلى ذلك.

2.2.1. رؤية متوسطة المستوى Mid-Level Vision :

تتضمن معالجة المستوى المتوسط مهاماً أخرى مثل تجزئة الصورة وإزالة تشفير الصورة ، والتعرف على الأشياء بشكل عام وما إلى ذلك في عملية المستوى المتوسط ، تكون المدخلات عبارة عن صور ومخرجاتها عبارة عن سمات الصورة بشكل عام.

3.2.1. رؤية عالية المستوى High Level Vision :

يضمن المستوى العالي تلك العمليات الأكثر تجريدياً في طبيعتها وتتضمن فهماً منطقياً لمجموعة من الكائنات التي تم التعرف في المستوى المتوسط .

3.1. Counting Objects (العد الكائن) :

1.3.1. مفهوم العد [2] :

العد هو تقدير عدد الكائنات في صورة ثابتة أو اطار فيديو له العديد من التطبيقات بما في ذلك عد الخلايا في الصورة المجهرية ، ومراقبة الحشود في أنظمة المراقبة وإجراء تعداد للحياة البرية .

4.1. طرق العد:

هناك ثلاث طرق للعد [1] هي:

1.4.1. العد عن طريق الكشف Count By Detection :

هو استخدام كاشف الكائن الذي يحدد موقع الكائنات ، هي إحدى تقنيات الرؤية الحاسوبية التي تسمح لنا بتحديد نوع وموقع الكائنات في صورة أو فيديو وبالتالي تمكننا هذه التقنية من معرفة عدد الكائنات .

2.4.1. العد عن طريق الانحدار Count By Regression:


هذه الطريقة تتجنب حل مشكلة الكشف الصعبة بدلا من ذلك ، يتم التعرف على تعيين مباشر لبعض الميزات العامة للصورة لعد الكائنات فيها، يمكن معالجة مشكلة الانحدار القياسية من خلال العديد من أدوات التعلم الآلي.

3.4.1. العد عن طريق التجزئة Count By Segmentation:

وهي بمثابة طرق هجينة للعد عن طريق الكشف والعد عن طريق الانحدار ، حيث يتم تجزئة الصورة إلى مجموعات منفصلة ثم يتم التعرف على تعيين مباشر لبعض الخصائص العامة لكل مجموعة منفصلة لتحديد العدد الإجمالي للكائنات الموجودة فيه.

5.1 أمثلة عن عد الكائنات الموجودة في الصورة [3]

: Example Of Counting Objects In The Picture



الشكل 01: مثال عن عد الكائنات في الصور

6.1. تطبيقات عد الكائنات في الصورة:

(Applications For The Number Of Objects In The Picture)

هناك العديد من تطبيقات عد الكائنات في صورة [1] نذكر منها:

1.6.1. عد المنتج ورقابة الجودة: Quality Control

✓ تحديد متى يجب ملء الرفوف ، والتعرف على وضع المنتج السيئ ، وتأكد من توفر المنتجات في خطوط التجميع في الوقت الفعلي.

2.6.1. حركة المرور Traffic Flow:

✓ يشمل ذلك مراقبة الحشود في أنظمة المراقبة ، مراقبة تدفق حركة المرور وتقدير الازدحام.

3.6.1. عد الخلايا Counting Cells :

✓ لتقدير عدد الخلايا الحية في صورة الفحص المجهرى كـالخلايا البكتيرية مثلا أو الفطريات (الشكل 02).



الشكل 02 : عد الخلايا البكتيرية ، عد الحشود في أنظمة المراقبة

7.1. الخلاصة:

في هذا الفصل كشفنا بعض المفاهيم الأساسية المرتبطة بمجال الصورة من خلال إعطاء بعض التعريفات الأساسية المتعلقة بهذا الموضوع، بدءاً من تعريف معالجات الصورة ومستوياتها وصولاً إلى تعريف عد الكائنات في الصور ، دراسة سريعة لطرق العد المستخدمة .

وفي الفصل الثاني سنعرض الطريقة المستخدمة لعد الكائنات في الصورة.

الفصل الثاني
التعلم الآلي والتعلم العميق
Machine Learning and Deep Learning

الفصل الثاني: التعلم الآلي والتعلم العميق

1.2. المقدمة

لقد كان لتعلّم الآلة Machine Learning و التعلم العميق Deep Learning نصيب كبير من الاهتمام في السنوات الأخيرة. خوارزميات التعلم الآلي ماهي إلا برامج يمكنها التّعلّم والتّحسين من التّجربة دون تدخلات بشريّة، بيد أن التعلم العميق يحاول أن يحاكي العقل البشري في جميع قدراته، والتي منها؛ الرؤية، وفهم الحديث. في هذا الفصل سيتم توضيح بعض تقنيات تعلم الآلة و التعلم العميق خصوصا تلك المستخدمة في منهجية عد الكائنات في الصورة.

2.2. الذكاء الاصطناعي (Intelligence Artificielle) :

الذكاء الاصطناعي هو تقنية تمكّن الآلة من محاكاة السلوك البشري و يُعدّ الذكاء الاصطناعي فرعاً من فروع علم الحاسوب التي تُعنى بخلق آلات وأجهزة ذكية. ويُعرّف أيضاً بأنّه محاكاة الدماغ البشري في القيام ببعض وظائفه المعقدة، مثل: (التعلم، والتخطيط، وتمييز الكلام، وحل المشكلات، والتفكير العقلي والمنطقي). وهو علم اختراع الآلات والبرامج الحاسوبية التي تتصف بالذكاء، والتعلم الآلي هو تقنية لتحقيق الذكاء الاصطناعي من خلال الخوارزميات المدربة بالبيانات ، وأخيراً يعتبر التعلم العميق نوعاً من التعلم الآلي المستوحى من بنية الدماغ البشري. من حيث التعلم العميق يسمى هذا الهيكل بالشبكة العصبية الاصطناعية [9]. (الشكل 03)



الشكل 03 : مجالات الذكاء الاصطناعي

3.2. تعليم الآلة (Machine Learning) :

هو تقنية ذكاء اصطناعي يمكن لأجهزة الكمبيوتر من التعلم دون أن تكون مبرمجة لهذا الغرض، وهو أسلوب يستخدم للاحتمال الاحصائي لمنح أجهزة الكمبيوتر القدرة على التعلم بمفردها دون برمجة واضحة، حيث تعتمد على فكرة أن الأنظمة يمكنها التعلم من البيانات وتحديد الأنماط واتخاذ القرارات بأقل تدخل بشري لتقليد الطريقة التي يتعلم بها البشر ، وتحسين دقتها تدريجياً [4] .

تعتبر مسائل التصنيف classification من أهم المسائل في عالم تعلم الآلة machine learning لأهميتها البالغة في الحياة الحقيقية في المجالات الصناعية والمكتبية ومن هنا اهتم الباحثون بهذا النوع من المسائل واخترعوا العديد من الخوارزميات المهمة ، و يمكن تقسيم مشاكل التعلم الآلي إلى 3 فئات عامة :

1.3.2 . تعلم الآلة الخاضع للإشراف Supervised Machine Learning :

عندما يكون لديك بيانات سابقة مع نتائج (تسميات في مصطلحات التعلم الآلي) وتريد توقع النتائج في المستقبل - ستستخدم خوارزميات التعلم الآلي الخاضعة للإشراف. يمكن تقسيم مشكلات التعلم الآلي الخاضعة للإشراف مرة أخرى إلى نوعين من المشكلات:

✚ مشاكل التصنيف Classification Problems

✚ مشكلة الانحدار Regression Problem

2.3.2. التعلم الآلي غير الخاضع للإشراف Unsupervised Machine Learning :

هناك أوقات لا تريد فيها توقع نتيجة بالضبط. أنت فقط تريد إجراء تجزئة أو تجميع. على سبيل المثال - قد يرغب البنك في تقسيم عملائه إلى شرائح لفهم سلوكهم. هذه مشكلة تعلم آلي غير خاضعة للإشراف لأننا لا نتوقع أي نتائج هنا.

3.3.2. تعزيز التعلم Reinforcement Learning :

يقال إنه أمل الذكاء الاصطناعي الحقيقي. وقد قيل ذلك بحق لأن الإمكانيات التي يمتلكها التعلم المعزز هائلة. إنه موضوع معقد قليلاً مقارنة بالتعلم الآلي التقليدي ولكنه موضوع مهم بنفس القدر للمستقبل.

2. 4. تعريف خوارزمية آلة المتجه الداعم SVM :

من بين خوارزميات التعلم الآلي نجد خوارزمية آلة المتجه الداعم support vector machine والتي يرمز لها svm وهي خوارزمية تعلم آلي خاضع للإشراف ، حيث تستخدم في مسائل التصنيف أو الانحدار و ترسم كل عنصر من عناصر البيانات كنقطة في الفضاء ذو بعد مع قيمة هي احداثيات معينة .


وهو عبارة عن أسلوب يجمع بين النظرية الإحصائية والتعليم الموجه ظهر من قبل الباحث فابنيك vapnik عام 1998 وتعتمد خوارزمية آلة المتجه الداعم على فكرة تحويل البيانات الأصلية إلى نمط جديد بشكل يميز البيانات في فضاء أعلى من فضاءها الأصلي حيث يمكننا من خلاله فصل البيانات وتصنيفها [10] .

1.4.2. استخدامات SVM (خوارزمية آلة المتجه الداعم):


تستخدم هذه الخوارزميات في تطبيقات تصنيف وتجزئة الصور Image Classification and Segmentation وتصنيف النصوص Category Assignment ، ومصنف في تطبيقات معالجة اللغات الطبيعية NLP وكذلك تصنيف البريد الإلكتروني فيما إذا كان مزيف Spam Email أو حقيقي Ham Email كذلك تحليل الآراء Sentiment Analysis وغيرها كما تستخدم في التطبيقات البيولوجية وغيرها من العلوم والتطبيق الأشهر استخدامها في التعرف على الأرقام المكتوبة بخط اليد في النظام البريد Postal Automation Services .

2.4.2 المستوى الفائق Hyperplane :

تعتمد فكرة خوارزمية آلة المتجه الداعم على البحث على أفضل طريقة لتقسيم البيانات إلى مجموعتين بوضع مستوي فائق hyperplane بينهما بغض النظر عن طبيعة البيانات سواء كانت قابلة للفصل الخطي أو لا وهنا تكمن مصدر قوتها. من الممكن أن يكون المستوى الفائق مُمثل في فضاء ثنائي البعد أي عبارة عن خط مستقيم إذا كان عدد المزايا features المدخلة 2، أو في فضاء ثلاثي البعد (مستوي) إذا كان عدد المزايا المدخلة 3، أو في فضاء مكون من n بعد إذا كان عدد المزايا المدخل n (الشكل 04).



المستوى الفائق في فضاء ثلاثي البعد




المستوى الفائق في فضاء ثنائي البعد

الشكل 04 : المستوى الفائق

3.4.2 المستوى الهامش Margin Level :

هو عبارة عن المسافة بين المستوي الفائق وأقرب نقطة من نقاط مجموعة البيانات بحيث كلما كانت هذه المسافة كبيرة كلما زادت احتمالية تصنيف بيانات جديدة بشكل صحيح ، فنلاحظ أن المستوى الفائق B هو أفضل من المستوي الفائق A وذلك لأن المسافة بينه وبين أي نقطة من نقاط متجهات الدعم أكبر ما يمكن وهذا ما يتيح إمكانية تصنيف أكبر عدد من النقاط بشكل صحيح. بالتالي تكمن أهمية الهامش في الحصول على الموضع الأفضل للمستوي الفائق، وهو ما يطلق عليه عبارة المستوي الفائق الأفضل (الشكل 05).



الشكل 05 : المستوى الهامش

5.2. التعلم العميق Deep Learning :

التعلم العميق Deep Learning هو مجموعة فرعية من التعلم الآلي Machine Learning ، والذي بدوره هو مجموعة فرعية من الذكاء الاصطناعي Artificial Intelligence .


وقد قام العلماء بدراسة العقل البشري وكيفية عمله من أجل أن يصمموا خوارزميات وبرامج قادرة على محاكاته، ولهذا السبب نجد أن تلك الخوارزميات مستوحاة من الدراسات الطبية والعصبية الخاصة بالإنسان وتحاول قدر الإمكان أن تقلدها، ولكن بطرق حاسوبية

لا بيولوجية [13]

1.5.2 الشبكات العصبية الاصطناعية Artificial Neural Network ANN

تتشكل الشبكات العصبية الاصطناعية من طبقات من العقد المتصلة. تستخدم نماذج التعلم العميق الشبكات العصبية التي تحتوي على عدد كبير من الطبقات. يتم إنشاء خوارزميات التعلم العميق مع طبقات متصلة [12] (الشكل 06).

Deep neural network



الشكل 06 : الشبكات العصبية الاصطناعية

الطبقة الأولى تسمى طبقة الإدخال أما الطبقة الأخيرة فتسمى طبقة الإخراج تسمى كل الطبقات الواقعة بينها الطبقات المخفية. تعني

كلمة عميق أن الشبكة تربط الخلايا العصبية في أكثر من طبقتين

في التعلم العميق ترتبط الخلايا العصبية ببعضها البعض ستقوم الخلايا العصبية بمعالجة ثم نشر إشارة الإدخال التي تستقبل الطبقة

فوقها تعتمد قوة الإشارة المعطاة للخلايا العصبية في الطبقة التالية على الوزن والتحيز ووظيفة التنشيط.


تستهلك الشبكة كميات كبيرة من بيانات الإدخال وتقوم بتشغيلها من خلال طبقات متعددة ، يمكن أن تتعلم الشبكة ميزات معقدة

بشكل متزايد للبيانات في كل طبقة.

2.5.2 الشبكات العصبية الملتفة Convolutional Neural Network CNN

الشبكة العصبية الالتفافية هي شبكة عصبية اصطناعية فعالة بشكل خاص ، وهي تقدم بنية فريدة من نوعها. يتم تنظيم الطبقات في ثلاثة أبعاد: العرض والارتفاع والعمق. لا تتصل الخلايا العصبية في طبقة واحدة بجميع الخلايا العصبية في الطبقة التالية ، ولكن فقط بمنطقة صغيرة من الخلايا العصبية للطبقة. يتم تقليل الناتج النهائي إلى متجه واحد من درجات الاحتمال ، منظمة على طول بعد العمق (الشكل 07).

تم استخدام الشبكات العصبية الالتفافية في مجالات مثل التعرف على الفيديو والتعرف على الصور وأنظمة التوصية.




الشكل 07 : الشبكة العصبية الالتفافية

3.5.2 عملية التعلم العميق Deep learning Process

توفر الشبكة العصبية العميقة دقة متطورة في العديد من المهام ، من اكتشاف الأشياء إلى التعرف على الكلام يمكنهم التعلم تلقائيًا، دون معرفة محددة مسبقًا مشفرة بشكل صريح من قبل المبرمجين.

التعلم يحدث على مرحلتين. تتكون المرحلة الأولى من تطبيق تحويل غير خطي للمدخلات وإنشاء نموذج إحصائي كمرجع. تهدف المرحلة الثانية إلى تحسين النموذج بطريقة رياضية تعرف باسم المشتق.

تكرر الشبكة العصبية هاتين المرحلتين من مئات إلى آلاف المرات حتى تصل إلى مستوى مقبول من الدقة (الشكل 08).



الشكل 08 : عملية التعلم العميق

6.2. تقنيات التعلم العميق مقابل التعلم الآلي

يقارن الجدول التالي بين تقنيتي التعلم الآلي و التعلم العميق [8]

التعلم العميق	التعلم الآلي	
يحتاج إلى استخدام كميات كبيرة من بيانات التدريب لإجراء التنبؤات.	يمكن استخدام كميات صغيرة من البيانات لإجراء التنبؤات.	عدد نقاط البيانات
يعتمد على الآلات الراقية. يقوم بطبيعته بعدد كبير من عمليات ضرب المصفوفة. يمكن لوحدة معالجة الرسومات تحسين هذه العمليات بكفاءة.	مكن أن تعمل على آلات منخفضة الجودة. لا يحتاج إلى كمية كبيرة من الطاقة الحاسوبية.	تبعيات الأجهزة
يتعلم ميزات عالية المستوى من البيانات وينشئ ميزات جديدة من تلقاء نفسه.	تطلب تحديد الميزات بدقة وإنشائها من قبل المستخدمين.	عملية الانجاز
تحرك من خلال عملية التعلم من خلال حل المشكلة على أساس شامل.	يقسم عملية التعلم إلى خطوات أصغر. ثم يجمع بين النتائج من كل خطوة في مخرج واحد.	النهج Learning

وقت التنفيذ	يستغرق القليل من الوقت نسبيا للتدريب ، بدءا من بضع ثوان إلى بضع ساعات.	عادة ما يستغرق التدريب وقتا طويلا لأن خوارزمية التعلم العميق تتضمن العديد من الطبقات.
المخرجات	عادة ما يكون الناتج قيمة عددية ، مثل درجة أو تصنيف.	يمكن أن يكون للإخراج تنسيقات متعددة ، مثل نص أو درجة أو صوت.

9.2. الخلاصة :

تعرفنا في هذا المقال على خوارزمية آلة المتجه الداعم التي تعتبر من أهم الخوارزميات المستخدمة في أغلب تطبيقات تعلم الآلة ، كما تطرقنا إلى مفهوم التعلم العميق هو مجموعة فرعية من التعلم الآلي الذي يعتمد على الشبكات العصبية الاصطناعية والفصل الموالي نتطرق إلى تصميم وتنفيذ المنهجية المتبعة لعد الكائنات في الصورة باستخدام التعلم الآلي والتعلم

العميق.

الفصل الثالث
التصميم و التنفيذ
Design and implementation

الفصل الثالث : التصميم و التنفيذ

1.3. المقدمة

التنفيذ هو تحقق أو إجراء عملي لخطة أو فكرة أو نموذج أو تصميم أو مواصفات أو معيار أو خوارزمية و قد يدخل ذلك في عدة مجالات منها السياسية وعلوم الكمبيوتر و تقنية المعلومات.

2.3. لغة برمجة المستخدمة : The Programming Language Used

هي لغة برمجة عالية المستوى سهلة التعلم و الاستخدام تم ابتكارها على يد المبرمج الهولندي جايدو فان روسم Guido van Rossum " في مركز العلوم و الحاسوب الآلي " CWI و تعتبر من أكثر اللغات انتشارا نظرا لطبيعة الاستخدامات التي توفرها حيث تتميز بسهولة استخدامها و امكانية تنفيذ المهام من خلالها بشكل أسهل و بعدد أوامر أقل مقارنة باللغات أخرى بالإضافة إلى قابلية التكيف مع لغات البرمجة الأخرى فيمكنك استخدامها في تطبيقات مكتوبة بلغات مثل C. C++ وهذا ما يفسر سبب ارتفاع شعبيتها بالنسبة إلى المطورين و المبرمجين و شركات التكنولوجيا (الشكل 09).



الشكل 09 : لغة البايثون

3.3. بيئة التطوير:

3-3-1: VISUAL STUDIO_:

هو بيئة تطوير متكاملة تم ابتكارها من شركة مايكرو سوفت إذ تم تصميمه لتطوير برامج الكمبيوتر الخاصة بنظام الويندوز ومواقع الانترنت كما يمتلك المبرمجون أيضا الإصدار الخاص بهم من Visual studio مما يمكنهم من العمل على الرموز مجانا (الشكل 10).



الشكل 10 : Visual Studio

3-2-3 : JUPYTER

هو أحد أشهر و أهم الادوات المستخدمة أثناء تحليل البيانات بالإضافة إلى ذلك هي شئ أساسي لا يستغني عنها العالم , و ذلك لما تقدمه من مميزات و خصائص تسهل التعامل مع البيانات و الشيفرة البرمجية حيث تعتبر أداة قوية يمكن إستخدامها في مشاريع علم البيانات و تعليم الآلي (الشكل 11).



الشكل 11 : Jupyter

4.3. المكتبات المستخدمة :

▪ تعلم الآلة Machine Learning :

توفر لغة python العديد من المكتبات التي تسهل التعامل مع الصور , تم استخدام في تعلم الآلة (Machine Learning) مجموعة من المكتبات (الشكل 3-01) يأتي شرحها فيما يلي :

```
import os
from skimage import io
import numpy as np
from sklearn import svm
from sklearn.model_selection import train_test_split
from sklearn.metrics import accuracy_score
import pickle
from patchify import patchify
import cv2
```

الشكل 3-01 : المكتبات المستخدمة (تعلم الآلة)

❖ Os

تسمح لنا مكتبة OS بتنفيذ اوامر تتعلق بنظام التشغيل مثل انشاء مجلدات جديدة وحذف واعادة تسمية مجلدات.

❖ Skimage

توفر وظائف سهلة الاستخدام لقراءة و عرض و حفظ الصور و يدعم جميع صيغ الصور مثل (PNG ,BMP,JPEG,TIFF) وتم استخدامها من أجل تحميل بيانات التدريب.

❖ Numpy

تم استخدامها من اجل التعامل مع المصفوفات.

❖ sklearn

مكتبة scikit-learn من المكتبات تعليم الآلة بلغة البايثون , وتحتوي علي العديد من الخوارزميات و الطرق المستخدمة في مجال تعليم الآلة مثل التصنيف (Classification) و الانحدار (Regression) بالإضافة لاستخدامها في مرحلة تجهيز البيانات و تقييم النماذج , وتم بناؤها بالاعتماد على مكتبات : (Scipy,Numpy,Matplotlib) و العديد من المكتبات الاخرى ,وفي التصنيف يوجد العديد من النماذج تم استخدام svm لتدريب البيانات.

❖ sklearn.model_selection

توفر دالة train_test_split() التي تقوم بتقسيم بيانات التدريب الى جزئين (جزء لتدريب و جزء الاختبار) و يكون التقسيم على حسب النسبة التي يتم تحديدها .

❖ sklearn. Metrics

توفر هذه المكتبة دالة accuracy_score(a,b) التي تقوم بدورها بارجاع نسبة التطابق بين المدخلين a و b حتى نتمكن من معرفة نسبة توقعات الصحيحة و الخاطئة لبيانات التدريب.

❖ pickle

تم استخدامها من اجل حفظ و تحميل النموذج الذي تم تدريبه.

❖ patchify

توفر مكتبة patchify دالة patchify() تسمح بتجزئة الصورة الاصلية الى صور صغيرة بحجم محدد حتى نتمكن من تدريب النموذج عليها .

❖ cv2

هي مكتبة برمجية مفتوحة المصدر تهدف لتطوير الرؤية الحاسوبية مطورة من قبل انتل (Intel) وتقوم بمعظم العمليات على الصور التي يحتاجها المبرمجين تم استخدامها من اجل قراءة صورة بتدرج الرمادي.

▪ التعلم العميق Deep Learning :

تم استخدام المكتبات التالية في التعلم العميق (الشكل 02-3) :

```
from tensorflow import keras
from tensorflow.keras import optimizers
from tensorflow.keras.models import Sequential
from tensorflow.keras.layers import Dense , Conv2D
from tensorflow.keras.preprocessing.image import ImageDataGenerator
from tensorflow.keras.utils import normalize
```

الشكل 02-3 : المكتبات المستخدمة (تعلم العميق)

❖ Tensorflow :

هي مكتبة برمجية مجانية ومفتوحة المصدر في مجال تعلم الآلة .تستخدم في العديد من المجالات الفرعية ولكن لها تركيز محدد في تدريب و استدلال الشبكات العصبية العميقة .

❖ Keras :

هي مكتبة شبكة عصبية مفتوحة المصدر مكتوبة في python وهو قادر على تشغيل برنامج MXNet , و في التعلم العميق تم تصميمه ليسمح بتجربة سريعة للشبكات العصبية العميقة , ويركز على أن يكون نموذجيا وقابلا للتوسعة .

5.3. المنهجية المتبعة :

اعتمدنا في البرنامج المنهجية التالية لعد الكائنات في الصورة (الشكل 12) :



الشكل 12 : ملخص عمل البرنامج

6.3. تحضير بيانات التدريب :

لتحضير بيانات تدريب نحتاج الى المكتبات (الشكل 3-03) التالية :

```

import os
import cv2
from patchify import patchify
import random
    
```

الشكل 3-03 : المكتبات المستخدمة (تحضير البيانات)

1.6.3. تحميل صورة بتدرج رمادي :

نقوم بتحميل الصورة بتدرج الرمادي (الشكل 3-04) كالتالي :

```

img = cv2.imread('C:\\Users\\nk\\Pictures\\20.jpeg',0)
    
```

الشكل 3-04 : قراءة صورة

مثلا لدينا الصورة الاتية (الشكل 13) :



الشكل 13 : صورة ملونة

بعد تنفيذ الكود السابق تكون الصورة كاتي (الشكل 14) :



الشكل 14 صورة بتدرج الرمادي


2.6.3. تجزئة الصورة :

نقوم بتجزئة الصور الى صور صغيرة مثلا اخترنا حجم 20x20 (نختار الصور التي يكون فيها حجم الكائن محصور في 20x20) ثم نجزء الصورة و نحفظ الصور الجزئية ليتم تصنيفها يدويا باستخدام مجموعة التعليمات التالية (الشكل 3-05) :

```
path= r'D:\\cour\\20x20'
os.chdir(path)
pat = patchify(img,(20,20),step=20)
for i in range(pat.shape[0]):
    for j in range(pat.shape[1]):
        pat_img = pat[i,j,:,:]
        r = str(random.randint(0,1000000000000000000))+'.jpg'
        cv2.imwrite( r,pat_img)
```

الشكل 3-05 : حفظ الصور

حيث نستخدم متغير path من اجل تحديد المسار الذي سيتم حفظ الصور فيه.
بعد تنفيذ الكود السابق نحصل على الاتي (الشكل 15) :




الشكل 15 : صور جزئية

3.6.3. تصنيف البيانات :

نقوم بتصنيف مجموعة الصور الي صنفين :

- مجموعة الصور التي تحتوي على الكائن بشكل واضح في مجلد (positive).
- مجموعة الصور لا يظهر فيها الكائن بشكل واضح في مجلد (negative) .



نكرر العملية على المئات من الصور للحصول على مجموعة بيانات جيد يمكن تدريب النموذج عليها .

7.3. الجزء التطبيقي :

■ استخدام خوارزمية SVM :

بعد تحضير بيانات التدريب كما هو موضح في الجزء السابق نقوم بتحميل مجموعة البيانات (الشكل 3-06) كاتي :

```
image =[]
name= []
data ='D:\\cour\\train'
categorize = [ 'true' , 'false']
file = ['negative','positive']
for i in file:
    folder_path = os.path.join(data,i)
    for img in os.listdir(folder_path):
        img = cv2.imread(os.path.join(folder_path,img),0)
        image.append(img)
        if(i== 'negative'):
            name.append('false')
        else :
            name.append('true')
```

الشكل 3-06 : تحميل البيانات (تعلم الآلة)

بعد تنفيذ التعليمات السابقة نحصل على مصفوفة خاصة بمجموعة الصور وقائمة خاصة بتسميات الصور بنفس الترتيب , بعد ذلك نقوم بتقسيم المصفوفة و القائمة الى جزئين جزء خاص بمجموعة التدريب و جزء خاص بمجموعة الاختبار (الشكل 07-3) كاتي :

```
image_train,image_test,name_train,name_test = train_test_split(image,name,test_size=0.25)
```

الشكل 07-3 : تجزئة البيانات

بعد ذلك نحتاج الى تغيير ابعاد المصفوفة (الشكل 08-3).

```
image_train = nb.array(image_train)
nsamples, nx, ny = image_train.shape
image_train = image_train.reshape((nsamples,nx*ny))

image_test = nb.array(image_test)
nsamples, nx, ny =image_test.shape
image_test =image_test.reshape((nsamples,nx*ny))
```

الشكل 08-3 : تغيير الابعاد

بعد ذلك نقوم بتدريب النموذج على البيانات باستخدام الدالتين fit() و predict() واستدعاء النموذج svm (الشكل 09-3) :

```
model = svm.SVC()
model.fit(image_train2,name_train2)
prediction = model.predict(image_test2)
```

الشكل 09-3 : تدريب - تنبؤ

بعد ذلك نحسب نسبة صحة التوقعات النموذج كتالي (الشكل 10-3) :

```
proportion = accuracy_score(name_test2,prediction)
proportion
```

الشكل 10-3 : نسبة الدقة

نقوم بتدريب النموذج عدة مرات حتى نتحصل على اعلى نسبة دقة.

نحفظ النموذج كتالي (الشكل 11-3) :

```
pickle.dump(model, open('model.pkl', 'wb'))
```

الشكل 11-3 حفظ النموذج

نستدعي النموذج كتالي (الشكل 12-3) :

```
model = pickle.load(open('bast_model.pkl', 'rb'))
```

الشكل 12-3 : استدعاء النموذج

الان نقوم بقراءة صورة ثم نمررها على النموذج فنحصل على قائمة (ذات القيم : true, false) ثم نحسب عدد مرات القيمة true كتالي (الشكل 13-3) :

```
img = cv2.imread('C:\\Users\\naami\\Pictures\\imm\\29.jpg',0)
pat = patchify(gray_img ,(20,20),step=16)

a,b,c,d = pat.shape
pat1 = pat.reshape((a*b,d*c))
prediction = model.predict(pat1)

total = list(prediction)
print(total.count("true"))
```

الشكل 13-3 : اختبار صورة جديدة

كلما كانت بيانات التدريب محضرة بشكل جيد كلما كانت نتاج اقرب ما يمكن للقيم الحقيقية. 🌈

▪ استخدام التعلم العميق Deep Learning :

نقوم بتحميل مجموعة البيانات كالاتي (الشكل 14-3) :

```
image_width = 20
image_height = 20
nb_train_images =162

train_datagen = ImageDataGenerator(rescale=1./255)
training_set = train_datagen.flow_from_directory(train_directory,
target_size=(image_width,image_height),
batch_size=10,shuffle=True,seed=13,class_mode='binary')
```

الشكل 14-3 : تحميل البيانات (تعلم العميق)

ثم نقوم بتدريب النموذج (الشكل 3-15) :

```
# Partie B. Réseau
modele = Sequential()
# Première couche de convolution : 64 neurones, motif 3x3, activ. relu
modele.add(Conv2D(64, kernel_size=3, padding= 'same' , activation= 'relu' ,
input_shape=(image_width,image_height,3)))

# Deuxième couche de convolution : 64 neurones
modele.add(Conv2D(64, kernel_size=3, padding= 'same' , activation= 'relu' ))
# Mise en commun (pooling)
modele.add(MaxPooling2D(pool_size=(2, 2)))
# Troisième couche de convolution : 64 neurones
modele.add(Conv2D(64, kernel_size=3, padding= 'same' , activation= 'relu' ))
# Mise en commun (pooling)
modele.add(MaxPooling2D(pool_size=(2, 2)))
# Quatrième couche de convolution : 64 neurones
modele.add(Conv2D(64, kernel_size=3, padding= 'same' , activation= 'relu' ))
modele.add(Dropout(0.5))
# Aplatissage
modele.add(Flatten())
# Couche de sortie : 2 classes
modele.add(Dense(32, activation= 'relu' ))
modele.add(Dense(1, activation= 'sigmoid' ))
# Descente de gradient
modele.compile(loss= 'binary_crossentropy' ,
optimizer= 'adam' ,
metrics=[ 'accuracy' ])
```

الشكل 3-15 تعريف طبقات النموذج

ثم نقوم بتدريب النموذج (الشكل 3-16) :

```
# Partie C. Apprentissage
history = modele.fit_generator(training_set,steps_per_epoch = 10, epochs = 10)
```

الشكل 3-16 : تدريب النموذج (تعلم العميق)

نسبة الدقة المتحصل عليها (الشكل 3-17) :

```
score = modele.evaluate(testing_set, verbose=0)
print( ' Test loss: ' , score[0])
print( ' Test accuracy: ' , score[1])
```

```
Test loss: 0.5390723943710327
Test accuracy: 0.7272727489471436
```

الشكل 3-17 : نتائج التدريب

حيث تمثل قيمة Test accuracy نسبة الدقة المتحصل عليها من خلال التدريب النموذج.

و تمثل Test loss نسبة الاخطاء خلال التدريب .

8.3. الخلاصة

في هذا الفصل قدمنا المراحل المختلفة لتنفيذ منهجية عد كائنات في صورة الخاص بنا لقد أوضحنا في نهاية الفصل النتائج التي حصل عليها نظامنا .

خاتمة عامة

خاتمة عامة

يعد عدد سنابل القمح في الحقل معلومات مهمة جداً للتنبؤ بنمو المحاصيل وتقدير مردودها ، وبالتالي فهي تحظى باهتمام بحثي متزايد باستمرار . للحصول على مثل هذه المعلومات ، نستخدم الذكاء الاصطناعي من خلال التعلم الآلي والشبكة العصبية لتقدير عدد حبات القمح في الصورة الرقمية.

في هذا التقرير ,قدمنا عملاً مخصص ركزنا فيه بشكل أساسي حول خوارزمية آلة المتجه الداعم SVM من جهة وتقنية التعلم العميق من جهة أخرى لتصنيف الصور المجزأة و استعمالها لعد حبات القمح في الصورة الرقمية.

يعتبر العدد المحسوب تقديراً لعدد حبات القمح في الصورة الرقمية و قد حصلنا على نتائج مقبولة في كلتا الطريقتين المتبعتين سواء التعلم الآلي عن طريق خوارزمية آلة المتجه الداعم SVM أو التعلم العميق عن طريق الشبكة العصبية الملتفة .

في المستقبل يمكننا تعزيز البيانات بصور أكثر لتحسين عمل الشبكة العصبية و امدادها بعدد أكثر من البيانات

قائمة المراجع

- [1] Lempitsky, Victor, and Andrew Zisserman. "Learning to count objects in images." Advances in neural information processing systems 23 (2010).
- [2] Wang, Jianfeng, et al. "Learning to count objects with few exemplar annotations." arXiv preprint arXiv:1905.07898 (2019).
- [3] Ranjan, V., Sharma, U., Nguyen, T., & Hoai, M. (2021). Learning to count everything. In Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition (pp. 3394-3403).
- [4] Machine Learning For Dummies ®, IBM Limited Edition
- [5] Low Level, Mid Level and High Level Image Processing | Asquero
- [6] tech:<https://www.arageek.com>
- [7] wiki <https://ar.m.wikipedia.org/wiki>
- [8] Azure Machine Learning | Microsoft Docs - التعلم العميق مقابل التعلم الآلي
- [9] الذكاء الاصطناعي باللغة العربية - Applications of Computer Vision - الرؤية الحاسوبية وتطبيقاتها (aiinarabic.com)
- [10] Support Vector Machine - الذكاء الاصطناعي باللغة العربية (aiinarabic.com)
- [11] What is Computer Vision? | IBM
- [12] ما هي الشبكات العصبية الاصطناعية وأنواعها وكيف تعمل - الراحون (alrab7on.com)
- [13] Deep Learning (Deep Learning) الباحثون السوريون - التعلم العميق (syr-res.com)