

الذكاء الاصطناعي الجيومكاني أسس ومفاهيم

بالتطبيق على برنامج ARCGIS PRO



م / أحمد محمود عباس

مدير قسم نظم المعلومات الجغرافية
بشركة عبد الرحمن جزار

د / رشا صابر نوفل

مدرس مادة بكلية الآداب جامعة المنوفية
مستشار نظم معلومات جغرافية بشركة عبد الرحمن جزار

2024

الذكاء الاصطناعي الجيومكاني

أسس ومفاهيم

بالتطبيق على برنامج ArcGISPro

م/ أحمد محمود عباس

مدير قسم نظم المعلومات الجغرافية

بشركة عبد الرحمن جزار

د/ رشا صابر نوفل

مدرس مادة بكلية الآداب جامعة المنوفية

مستشار نظم معلومات جغرافية بشركة عبد الرحمن جزار

2024

بسم الله الرحمن الرحيم
وما اوتيتم من العلم إلا قليلاً
الإسراء آية 85

إهداء

إلى أبطالنا الصغار بفلسطين الحبيبة ، الذين فقدوا أرواحهم في سبيل الحرية والعدالة، هذا الكتاب مخصص لذكراكم الخالدة ولروحكم التي تضيء دربنا. رغم صغر سنكم، أثرتم بأعماقنا وأكثرتم من حب الحياة والأمل في قلوبنا.

إلى الأب الروحي لطلاب نظم المعلومات الجغرافية الأستاذ الدكتور جمعة داواد

فهرس الموضوعات

رقم الصفحة	الموضوع
5	إهداء
7	تقديم
8	مقدمة
9	المفاهيم الرئيسية
12	الفصل الأول : مبادئ التعلم الآلي:
13	تعريف التعلم الآلي
14	أنواع التعلم الآلي
14	التعلم الآلي الخاضع للإشراف
16	التعلم الآلي غير الخاضع للإشراف
40	الفصل الثاني : خوارزميات تعلم الآلة:
41	شجرة اختيار الخوارزمية المناسبة
51	خوارزميات التعلم الإشرافي (التوقع Regression)
63	خوارزميات التعلم غير الإشرافي (Clustering)
75	الفصل الثالث : أسس التعلم العميق Deep Learning :
76	مقدمة
79	كيف تتعلم الشبكة العصبية؟
89	الشبكات العصبية الاصطناعية
96	الفصل الرابع : أنواع الشبكات العصبية الاصطناعية:
98	الشبكات العصبية التلافيفية (CNNs)
100	الشبكات العصبية المتكررة (RNNs)
100	شبكات الذاكرة طويلة المدى (LSTMs)
103	شبكات الخصومة التوليدية (GANs) Generative Adversarial Network
104	شبكات وظيفة الأساس الشعاعي (RBFNs)
105	بيرسيبترون متعدد الطبقات (MLPs)
106	خرائط التنظيم الذاتي (SOMs)
108	شبكات المعتقدات العميقة (DBNs)
109	آلات Boltzmann المقيدة (RBMs)
110	أجهزة التشفير التلقائي (Autoencoders)

111	شبكات هوبفيلد العصبية Hopfield Neural Network
111	الشبكات العصبية المغذية (FNNs)
114	الفصل الخامس: أدوات الذكاء الاصطناعي الجيومكاني برنامج ArcGIS Pro :
115	مقدمة
119	تجهيزات بيئة العمل
121	شريط أدوات داخل Imagery
121	مجموعة أدوات Deep Learning
611	مجموعة أدوات GeoAI Tools
183	الفصل السادس تطبيقات الذكاء الاصطناعي الجيومكاني على برنامج ArcGIS Pro :
184	استخراج المباني من الصور الفضائية
193	رسم خرائط الغطاء الأرضي باستخدام صورة جوية عالية الدقة (الدرونز):
199	استخراج النخيل باستخدام المرئيات الفضائية
200	تحديد صحة النخيل
205	استخراج النصوص من الصور
209	معرفة اعداد الحشود من صور ملتقطة
212	توقيع الاشجار من صور الطائرات بدون الطيار
213	استخراج خطوط الكهرباء من بيانات الليدار
225	المراجع

تقديم

بسم الله الرحمن الرحيم والصلاة والسلام على اشرف الخلق سيدنا ونبينا محمد صل الله عليه وسلم أما بعد ؛ جاء هذا الكتاب بعنوان الذكاء الاصطناعي الجيومكاني أسس ومفاهيم بالتطبيق على برنامج ArcGIS Pro ليكون حجر الأساس للمهتمين بمواكبة التطور الهائل في تقنيات نظم المعلومات الجغرافية وتوفير البيانات الضخمة وبيانات الوقت الحقيقي وانترنت الأشياء والتحول الرقمي من أجل استخدام الذكاء الاصطناعي في ادارة وتنمية البيئة حيث يفتح المجال لفهم الأساس النظري للذكاء الاصطناعي الجيومكاني و يمكننا من استخدام أدوات الذكاء الاصطناعي في برنامج ArcGIS Pro ونحن على دراية بالمفاهيم النظرية للعلم ذاته ؛ للقدرة على تفسير النتائج واستخدام النماذج المثلى ذات الجدوى بمشكلة الدراسة ؛ وذلك من خلال ستة فصول تسبقهما مقدمة حيث جاء الفصل الأول لتوضيح مبادئ تعلم الآلة ؛ بينما يشرح الفصل الثاني خوارزميات تعلم الآلة بأنواعها في حين أن الفصل الثالث يعرض أسس التعلم العميق ليأتي الفصل الرابع لتوضيح أنواع الشبكات العصبية الاصطناعية ؛ وأخيراً يأتي الفصل الخامس والسادس للتطبيق على برنامج ArcGIS Pro حيث جاء الفصل الخامس بشرح أدوات الذكاء الاصطناعي (تعلم الآلة والتعلم العميق) والفصل السادس بتطبيقات على استخدام الذكاء الاصطناعي الجيومكاني في برنامج ArcGIS Pro.

المؤلف

رشا صابر نوفل
أحمد محمود عباس

مقدمة

الذكاء الاصطناعي الجيومكاني : GeoAI

يلعب الذكاء الاصطناعي (AI) دورًا متزايد الأهمية في تعزيز فهمنا لعلوم الأرض وقدرتنا على مواجهة التحديات الملحة للتغير البيئي. توفر نماذج الذكاء الاصطناعي أدوات قوية لتحليل مجموعات البيانات الضخمة والمعقدة الناتجة عن منصات الاستشعار عن بعد، ونماذج المناخ، وأنظمة المراقبة البيئية. ومع ذلك، من الضروري أن يكون لدينا نماذج دقيقة وفعالة لتحليل البيانات الجغرافية المكانية، خاصة في الحالات التي تكون فيها البيانات المصنفة نادرة. ولسوء الحظ، فإن تطوير مثل هذه النماذج يشكل تحديًا كبيرًا في العديد من التخصصات.

يكمن أحد التعقيدات الرئيسية في الطبيعة الموزعة لبيانات علوم الأرض. غالبًا ما يكون الوصول إلى هذه البيانات وتحليلها أمرًا صعبًا ويستغرق وقتًا طويلاً، مما يجعل من الصعب تطوير نماذج وتطبيقات فعالة للذكاء الاصطناعي لحل التحديات الملحة في علوم الأرض. وقد أدت هذه الظروف إلى الحاجة إلى مهارات وأدوات أكثر تخصصًا للتدريب ونشر النماذج، مما يضيف طبقة أخرى من التعقيد إلى مهمة صعبة بالفعل. وما يزيد الأمور صعوبة أن التوفر المحدود لبيانات الحقيقة الأرضية لأغلب التطبيقات غالبًا ما يؤدي إلى نماذج ذكاء اصطناعي ذات دقة تنبؤية ضعيفة، وهو ما قد يحد بشدة من تأثيرها.

للتغلب على هذه المشكلات، من الضروري تطوير نماذج أفضل يمكنها التنبؤ بالبيانات الجغرافية المكانية وتحليلها بدقة، حتى عندما تكون البيانات المصنفة نادرة. أحد الحلول المحتملة لهذه المشكلة هو استخدام نماذج الأساس الجغرافي المكاني، وهي نماذج مدربة مسبقًا تستخدم بيانات الاستشعار عن بعد ويمكن ضبطها بدقة لمهام مختلفة. وقد أظهرت هذه النماذج بالفعل فعاليتها في تطبيقات مثل رسم خرائط الكوارث على سبيل المثال، الكشف عن الفيضانات، والكشف عن الحروق، ومراقبة التغير البيئي على سبيل المثال، استخدام الأراضي، وتغير الأراضي، واكتشاف البيانات مثل، إعادة بناء الصور، والبحث عن التشابه. هناك أيضًا اهتمام متزايد بمواصلة تطوير هذه النماذج وتكييفها لاستخدامها في التحليلات الجغرافية المكانية لاتخاذ القرارات الحاسمة.

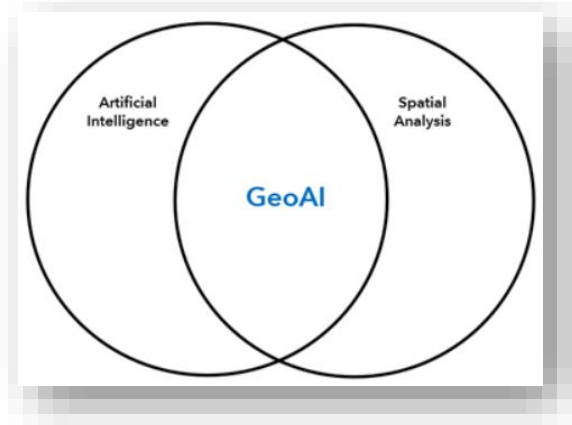
المفاهيم الرئيسية:

GeoAI

الذكاء الجيومكاني هو مجال علمي ناشئ متعدد التخصصات يقوم على تسخير إبتكارات العلوم المكانية والتعلم الآلي والتعلم العميق ، وإستخراج البيانات ، والحوسبة لإكتشاف المعرفة الجغرافية المكانية وإستخراج معلومات مفيدة من البيانات المكانية الضخمة .

فهو تكامل الذكاء الاصطناعي (AI) مع البيانات المكانية لزيادة فهم المكان وحل مشكلاته ؛ فيتضمن GeoAI تطبيق تقنيات الذكاء الاصطناعي التقليدية لتوليد البيانات المكانية من خلال استخراج المعلومات وتصنيفها واكتشافها من البيانات المنظمة وغير المنظمة .

لهذا تعود أهمية GeoAI في قدرته علي إستنباط المعنى من مجموعة البيانات المعقدة ، وإمكانية تحويل البيانات إلى معلومات، وتحسين جودة البيانات واتساقها ودقتها ، وتسريع الوقت اللازم لتحقيق الفهم الكامل للمكان ، ويساعد أيضا في إيجاد حلول أكثر كفاءة وأكثر دقة للمشكلات الجيومكانية ، وإتخاذ القرارات وبالتالي بناء مستقبل يتسم بالاستدامة .



التحليل المكاني :

التحليل المكاني هو نهج تحليلي يستخدم في فهم وتحليل البيانات المكانية، وهي البيانات التي ترتبط بالمواقع الجغرافية . يهدف التحليل المكاني إلى استكشاف العلاقات والأنماط الجغرافية في البيانات، وتفسيرها لفهم الظواهر المكانية واتخاذ القرارات بشأنها. يستخدم التحليل المكاني مجموعة متنوعة من الأساليب والتقنيات الإحصائية والجغرافية، مثل نظم المعلومات الجغرافية والتحليل الإحصائي الجغرافي والنمذجة الجغرافية والتصوير المكاني، لفهم وتفسير البيانات المكانية. تتضمن تطبيقات التحليل المكاني تحليل الانتشار الجغرافي وتحليل العلاقات المكانية وتحليل الانماط المكانية وتحليل الشبكات والتنبؤات .

الذكاء الاصطناعي (AI) :

قدرة الآلة على أداء المهام التي تتطلب محاكاة الذكاء البشري، مثل الإدراك والاستدلال والتعلم. إننا نرى تطبيقات الذكاء الاصطناعي في كل مكان في حياتنا اليومية في المساعدات الذكية على هواتفنا، وفي التوصيات على قنوات التواصل الاجتماعي، وفي السيارات ذاتية القيادة والروبوتات.

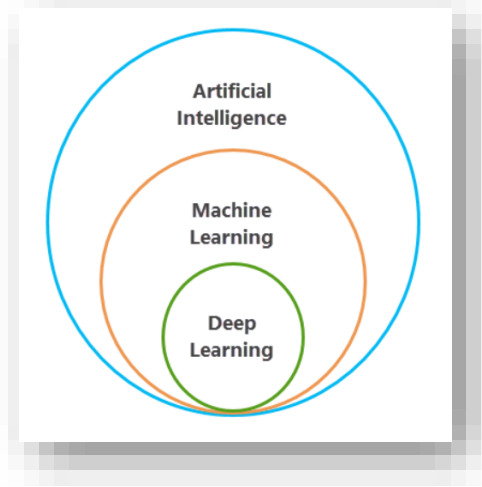
يشمل الذكاء الاصطناعي على كلا من التعلم الآلي والتعلم العميق:

التعلم الآلي (ML) :

مجموعة فرعية من الذكاء الاصطناعي تشير إلى مجموعة من التقنيات التي تسمح لأجهزة الكمبيوتر بتعلم الأنماط داخل البيانات واكتساب المعرفة دون برمجتها بشكل صريح. تأتي تقنيات تعلم الآلة عادة في شكل طرق إحصائية أو خوارزميات تعتمد على البيانات والتي تحل بعض المشكلات.

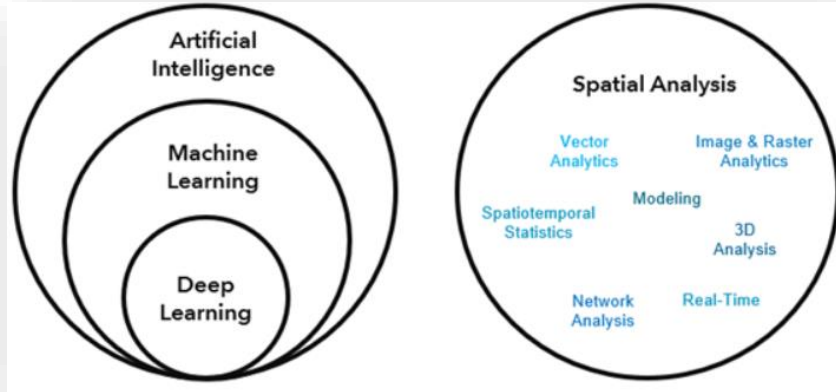
التعلم العميق (DL) :

مجموعة فرعية من تعلم الآلة تستخدم خوارزميات قابلة للتدريب في شكل شبكات عصبية اصطناعية. حيث إن البنية متعددة الطبقات لهذه الشبكات مستوحاة من كيفية عمل الدماغ البشري، حيث يتعلم البشر ويفهمون العالم من حولهم كتسلسل هرمي متداخل من المفاهيم. فخوارزميات DL تعمل مثل الدماغ البشري، حيث يتعلم الكمبيوتر أنماطاً ومفاهيم معقدة من خلال تجميع مفاهيم أبسط معاً. يتم تحليل بيانات الإدخال الأولية من خلال طبقات مختلفة من الشبكة، حيث تتعلم كل طبقة متتالية وتلتقط تعريفات الظواهر والأنماط الأكثر تعقيداً وتحديداً في البيانات.



الجانب الرئيسي الآخر لـ GeoAI هو تطبيق التعلم الآلي وتقنيات التعلم العميق، بما في ذلك تقنيات الإحصاءات والتعلم الآلي الواضحة مكانياً، لتحليل البيانات المكانية لتطبيقات مثل اكتشاف الأنماط المكانية وإجراء التنبؤات والتنبؤات الزمانية المكانية. إن استخدام التعلم الآلي الناشئ وأدوات التعلم العميق مع البيانات المكانية يمنح الممارسين بدائل جديدة

لاستكشاف مساحات المشكلات الصعبة. إن استخدام أساليب التعلم الآلي على البيانات المكانية، بالإضافة إلى دمج النماذج المكانية الواضحة التي تتضمن بعض جوانب الجغرافيا (الموقع، والشكل، والقرب، والمزيد) مباشرة في الخوارزمية لا يمكن أن يجعل النماذج أكثر كفاءة فحسب، بل أيضًا في كثير من الأحيان أكثر دقة وتمثيلًا للواقع الذي نهدف إلى تجسيده. يمكن استخدام هذه التقنيات لتخصيص الموارد بناءً على أنماط مكانية ذات معنى، للعثور على الاتجاهات والشذوذات في المكان والزمان، ودمج العلاقات المكانية في التنبؤات والتنبؤات.




التصنيف الجغرافي الذكي :

يشمل هذا المفهوم تطبيق تقنيات الذكاء الاصطناعي لتصنيف البيانات الجغرافية، مثل تصنيف أنواع الأراضي، أو تصنيف الصور الجوية لتحديد المعالم الطبيعية أو البنى التحتية.

التنبؤات المكانية الذكية :


عبارة عن استخدام الذكاء الاصطناعي في تحليل البيانات الجغرافية لتوقع الأحداث المستقبلية أو التغيرات في الظروف الجغرافية، مثل تنبؤات الطقس أو احتمالات حدوث الكوارث الطبيعية.



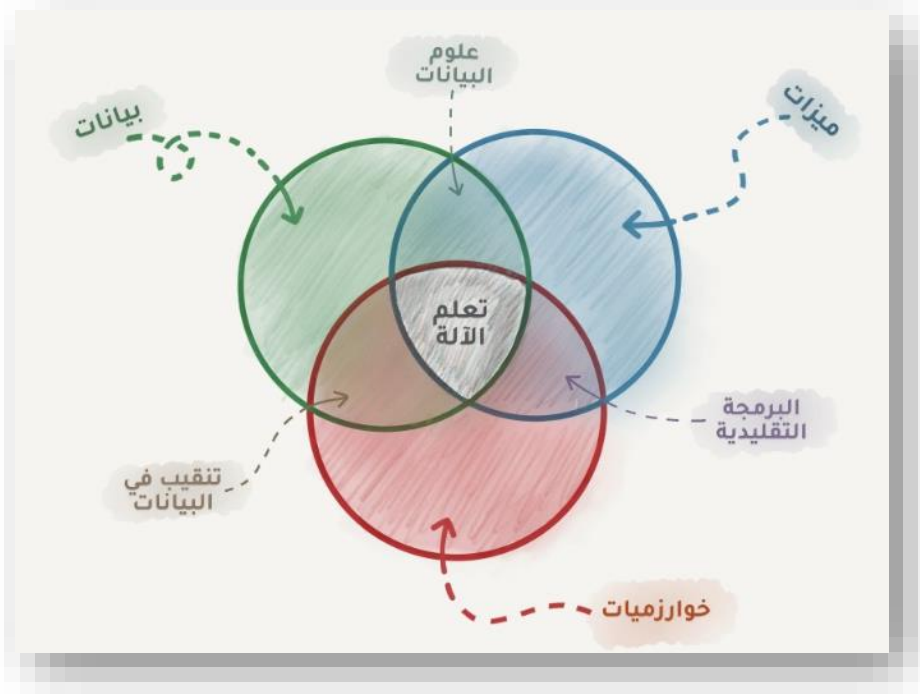
تعريف التعلم الآلي:

يشير التعلم الآلي على أنها فرع من الذكاء الاصطناعي يركز على تطوير التقنيات التي تسمح للأنظمة الحاسوبية بالتعلم من البيانات والتكيف مع التغيرات بدون الحاجة إلى برمجة صريحة لكل تغيير في البيئة أو المهمة. بشكل عام، يمكن تعريف التعلم الآلي على أنها مجموعة من الخوارزميات والتقنيات التي تعتمد على البيانات والتي تعمل على أتمتة التنبؤ والتصنيف وتجميع البيانات؛ يلعب التعلم الآلي دورًا مهمًا في حل المشكلات المكانية.

دائرة التعلم الآلي:

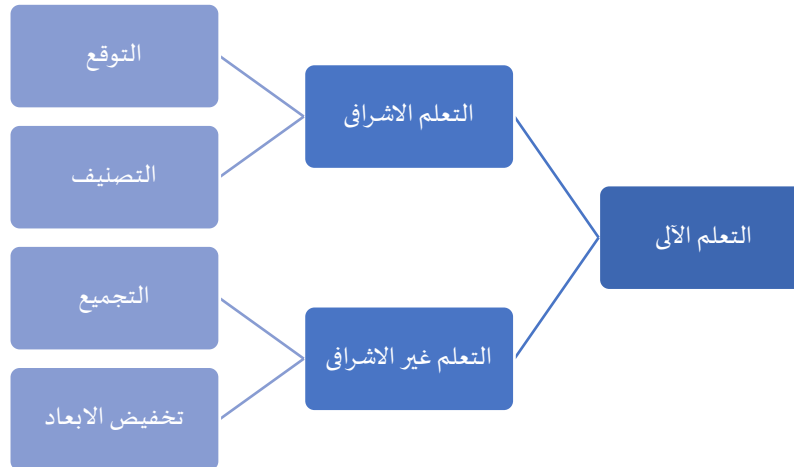


مكونات تعلم الآلة:



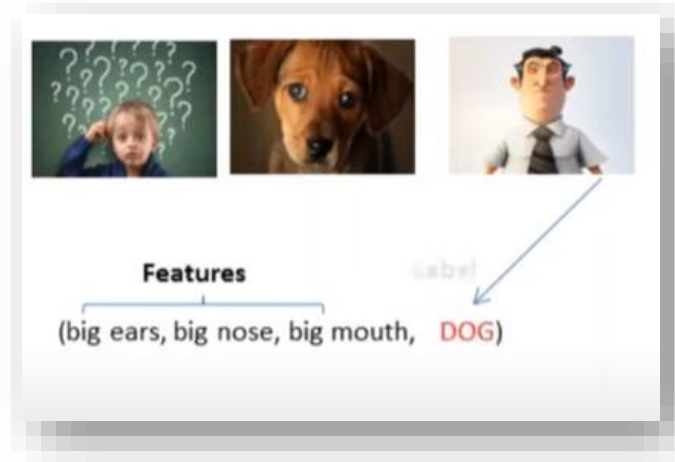
أنواع التعلم الآلي:

هناك أنواع متعددة من التعلم الآلي، ويجب معرفة الفرق بينهما وذلك للقدررة على اختيار النوع المناسب على حسب ما نحاول التنبؤ به.



التعلم الآلي الخاضع للاشراف :Supervised machine learning

التعلم الخاضع للاشراف يستلزم وجود شخص مشرف على عملية التعلم حيث يتم تمييز الاشياء من خلال مسمياتها Labeled وهي تماما تشبه الطفل حين يتلقى معلوماته من الوالد (بمثابة المشرف في عملية التعلم) ؛ ليبدأ الطفل في تكوين صورة عن كل ما يتعلمه فمثلا عند رؤيته للقطعة لأول مرة يسأل المشرف على التربية عن ما يراه فيعطى المشرف مسمى القطعة ويبدأ الطفل في تكوين صورة القطعة في ذهنه وفيما بعد حينما يرى القط (المواصفات التي اصبحت عالقة في ذهنه) يعرف تلقائى انها قطة



خلاصة القول ان التعلم الآلي الخاضع للإشراف هو مصطلح عام لخوارزميات التعلم الآلي حيث تتضمن بيانات التدريب كلا من قيم الميزات وقيم التسمية المعروفة. يتم استخدام التعلم الآلي الخاضع للإشراف لتدريب النماذج من خلال تحديد العلاقة بين الميزات والتسميات في الملاحظات السابقة، بحيث يمكن التنبؤ بتسميات غير معروفة للميزات في الحالات المستقبلية.

الانحدار أو التوقع Regression : هو شكل من أشكال التعلم الآلي الخاضع للإشراف حيث تكون التسمية المتوقعة من قبل النموذج قيمة رقمية. على سبيل المثال (سعر بيع العقار بناء على مساحته، وعدد الغرف به، ومقاييس اخرى مثل الموقع).

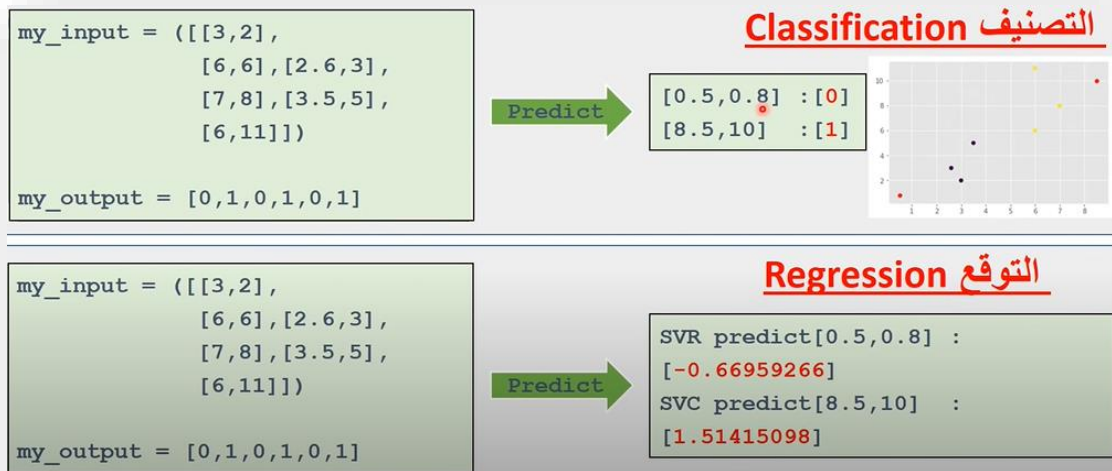
التصنيف Classification :التصنيف هو شكل من أشكال التعلم الآلي الخاضع للإشراف حيث تمثل التسمية تصنيفا أو فئة. هناك سيناريوهان شائعان للتصنيف مثال تصنيف الكائنات المختلفة بناء على صفاتها أو تصنيف الصور .

التصنيف الثنائي Binary classification

في التصنيف الثنائي، تحدد التسمية ما إذا كان العنصر الذي تمت ملاحظته هو أم لا أى ان نماذج التصنيف الثنائي تتنبأ بواحدة من نتيجتين متبادلتين فقط ايجابي أو سلبى (0 و 1) على سبيل المثال التنبؤ بما إذا كان المريض معرضا لخطر الإصابة بمرض محدد مثل مرض السكر بناءاً إلى مقاييس سريرية مثل الوزن والعمر ومستوى الجلوكوز في الدم الخ.

تصنيف متعدد الفئات Multiclass classification :

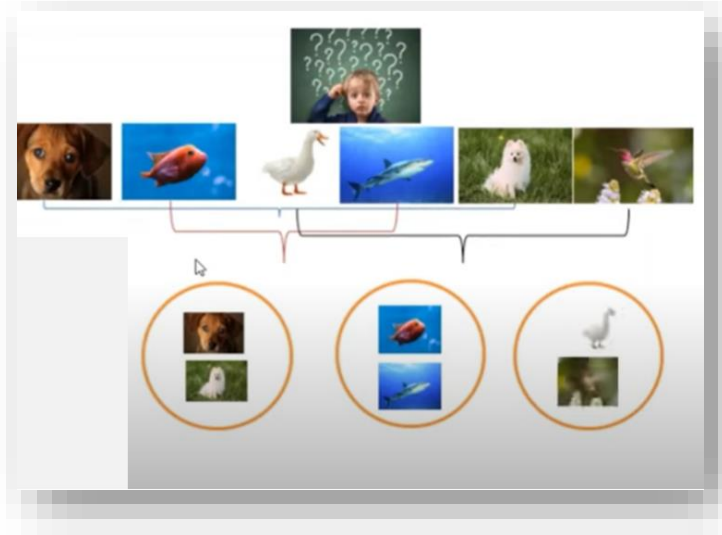
التصنيف متعدد الفئات يسمح للتنبؤ بتسمية تمثل واحدة من فئات محتملة متعددة. على سبيل المثال، التنبؤ بأنواع الحيوانات المختلفة استنادا إلى احجامها وقياستها المادي أو التصنيف حسب العمر (طفل – شاب – كهل).



التعلم الآلي غير الخاضع للإشراف : Unsupervised machine learning

يتضمن التعلم الآلي غير الخاضع للإشراف نماذج تدريب باستخدام البيانات التي تتكون فقط من قيم الميزات دون أي تسميات معروفة. تحدد خوارزميات التعلم الآلي غير الخاضعة للإشراف العلاقات بين ميزات الملاحظات في بيانات التدريب.

ولتوضيح هذا النوع على مثال الطفل الذي يتلقى التعلم من المشرف (الأب) فنتخيل عدم وجود الاب في هذه الحالة فعند مشاهدة الطفل للكائنات فيتعلم الطفل بمفرده عن طريق ملاحظة العقل البشري للصور ويبدأ العقل في جمع الصفات المتشابهة من هذه الصور في مجموعات تسمى Clustering



أى أن تعلم الآلة غير الخاضع للإشراف هو عندما تعطي الخوارزمية بيانات إدخال بدون أي بيانات إخراج مصنفة. ثم تتعرف الخوارزمية من تلقاء نفسها على الأنماط والعلاقات داخل البيانات وفيما بينها. فيما يلي بعض أنواع تقنيات التعلم غير الخاضع للإشراف.

أنظمة المجموعات Clustering

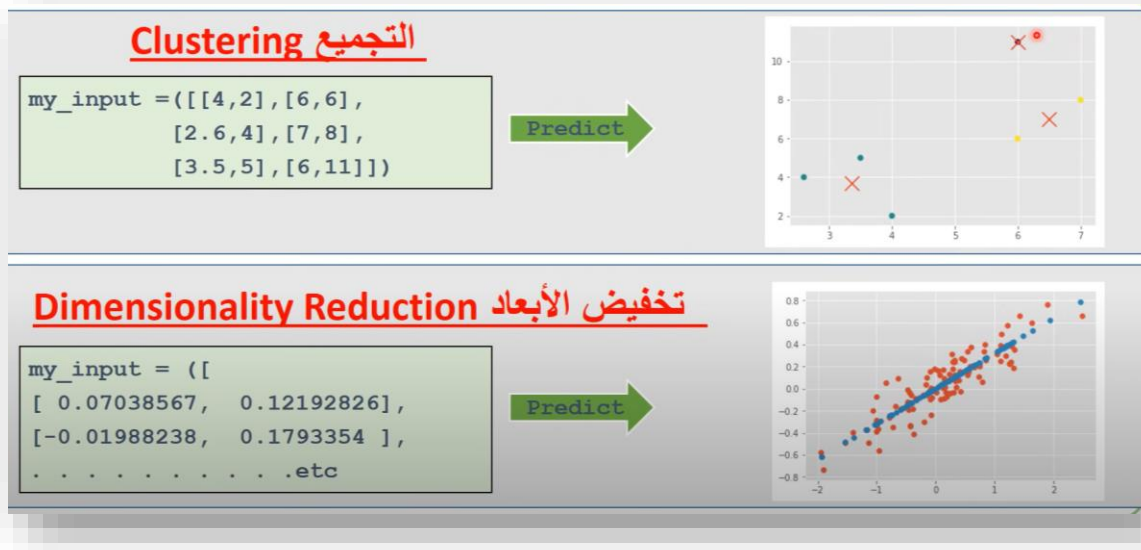
النموذج الأكثر شيوعاً للتعلم الآلي غير الخاضع للإشراف هو التجميع. تحدد خوارزمية التجميع أوجه التشابه بين الملاحظات استناداً إلى ميزاتهما، وتقوم بتجميعها في مجموعات منفصلة.

قد يشبه التجميع التصنيف متعدد الفئات؛ في أنه يصنف الملاحظات إلى مجموعات منفصلة. الفرق هو أنه عند استخدام التصنيف، فأنت تعرف بالفعل الفئات التي تنتمي إليها الملاحظات في بيانات التدريب؛ لذلك تعمل الخوارزمية عن طريق تحديد العلاقة بين الميزات وتسمية التصنيف المعروفة. في التجميع، لا توجد تسمية نظام مجموعة معروفة مسبقاً وتقوم الخوارزمية بتجميع ملاحظات البيانات استناداً إلى تشابه الميزات فقط.

في بعض الحالات، يتم استخدام التجميع لتحديد مجموعة الفئات الموجودة قبل تدريب نموذج التصنيف. على سبيل المثال، قد تستخدم التجميع لتقسيم العملاء إلى مجموعات، ثم تحليل هذه المجموعات لتحديد فئات مختلفة من العملاء وتصنيفها (قيمة عالية - حجم منخفض ومشتري صغير متكرر وما إلى ذلك). يمكنك بعد ذلك استخدام التصنيفات الخاصة لتسمية الملاحظات في نتائج التجميع واستخدام البيانات المسماة لتدريب نموذج تصنيف يتنبأ بفئة العميل التي قد ينتمي إليها عميل جديد.

تخفيض الأبعاد:

هي الأساليب التي تستخدم لتحويل مجموعات من البيانات ذات الأبعاد العالية إلى تمثيلات ذات أبعاد منخفضة أو مشتقات منها. تساعد هذه التقنيات على التخلص من الضجيج، وتسهيل عمليات التصنيف والتنبؤ، وتسريع وتبسيط معالجة البيانات.



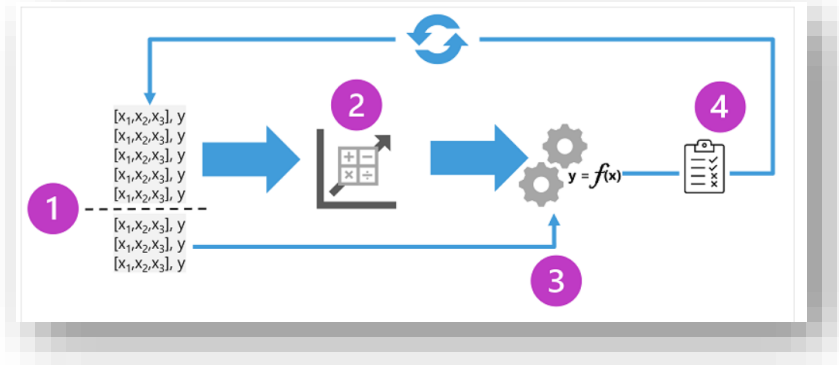
أولاً:- الانحدار أو التوقع Regression

يتم تدريب نماذج الانحدار على التنبؤ بقيم التسميات الرقمية استناداً إلى بيانات التدريب التي تتضمن كل من الميزات والتسميات المعروفة. تتضمن عملية تدريب نموذج الانحدار (أو أي نموذج تعلم آلي خاضع للإشراف) تكرارات متعددة تستخدم فيها خوارزمية مناسبة لتدريب النموذج، وتقييم الأداء التنبؤي للنموذج، وتحسين النموذج عن طريق تكرار عملية التدريب باستخدام خوارزميات ومعلمات مختلفة حتى تحقق مستوى مقبولاً من الدقة التنبؤية.

لتدريب نموذج التعلم الآلي الخاضعة للإشراف أربعة عناصر رئيسية هي:

1. تقسيم بيانات التدريب عشوائياً لإنشاء مجموعة بيانات لتدريب النموذج و مجموعة فرعية من البيانات التي ستستخدمها للتحقق من صحة النموذج المدرب (بيانات تدريب وبيانات اختبار).

2. استخدم الخوارزمية المناسبة للبيانات المستخدمة .
3. استخدم بيانات التحقق من الصحة بها لاختبار النموذج عن طريق التنبؤ بتسميات الميزات .
4. مقارنة التسميات الفعلية المعروفة في مجموعة بيانات التحقق من الصحة بالتسميات التي توقعها النموذج .
وتجميع الاختلافات بين قيم التسمية المتوقعة والقيم الفعلية لحساب مقياس يشير إلى مدى دقة النموذج المتوقع لبيانات التحقق من الصحة.



ملحوظة: بعد كل تدريب والتحقق من صحة التكرار وتقييمه، يمكن تكرار العملية باستخدام خوارزميات ومعلمات مختلفة حتى يتم تحقيق مقياس تقييم مقبول.

مثال لاستخدام التوقع

عندما نقوم بتدريب نموذجاً للتنبؤ بتسمية رقمية (y) استناداً إلى قيمة ميزة واحدة (x) : على سبيل المثال، نقوم بتدريب نموذج يتوقع لنا عدد المسافرين إلى منطقة ما (y) وفقاً لدرجات الحرارة (X)

المسافرين	درجة الحرارة
1	51
0	52
14	67
14	65
23	70
20	69
23	72
26	75
22	73
30	81
26	78
36	83

تدريب نموذج انحدار:


سنبدأ بتقسيم البيانات واستخدام مجموعة فرعية منها لتدريب نموذج (بيانات التدريب) واستخدام مجموعة فرعية أخرى لتدريب النموذج (بيانات الاختبار)

بيانات الاختبار


المسافرين (y)	درجة الحرارة (X)
0	52
14	67
23	70
22	73
36	83

بيانات التدريب

المسافرين (y)	درجة الحرارة (X)
1	51
14	65
20	69
23	72
26	75
30	81
26	78



لتطبيق خوارزمية على بيانات التدريب وملاءمتها مع دالة تطبق عملية على x لحساب قيم y يتم استخدام خوارزمية الانحدار الخطي) وتستخدم عن طريق رسم خط يقوم على تقليل متوسط المسافة بين الخط والنقاط المرسومة



هنا اصبح الخط بمثابة تمثيل مرئي للدالة حيث يمكن من خلال ميل الخط حساب قيمة y لقيمة معينة من x فمثلا عندما يكون x 50 فقيمة y هو 0.

ومن خلال التدقيق في الخط المرسوم نجد أن كل زيادة 5 على طول المحور س إلى زيادة 5 لأعلى المحور ص ؛ فعندما كانت قيمة x هو 55، y هو 5؛ وعندما تكون x هو 60، y هو 10، وهكذا.

ومن هذا المنطلق يمكن بسهولة وضع دالة لحساب قيمة y لقيمة معينة من x ، بطرح الدالة من 50؛ بمعنى آخر، يمكن التعبير عن الدالة كما يلي:

$$f(x) = x - 50$$

حيث $f(x)$ function of x وهي دالة التي تُعبر عن الاحتمال الشرطي.

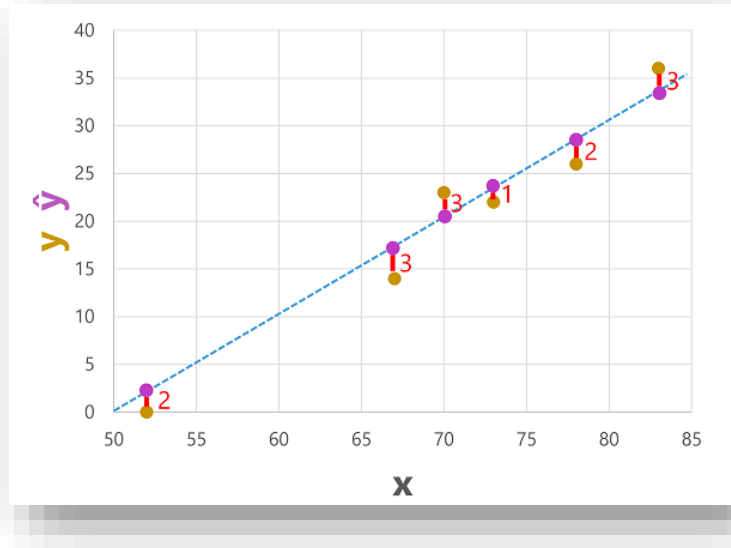
ولفهم الدالة يمكن استخدامها للتنبؤ بقيمة Y مع أي درجة حرارة . على سبيل المثال، افترض أن توقعات الطقس تخبرنا أنه غدا ستكون 77 درجة. يمكننا تطبيق نموذجنا لحساب قيمة Y 50-77 والتنبؤ بأن عدد المسافرين 27 غدا.

ولكن السؤال الذي يتبادر إلى أذهاننا الآن ما مدى دقة نموذجنا؟

ولتقييم نموذج الانحدار و للتحقق من صحة النموذج وتقييم مدى توقعه، يتم استخدام بيانات الاختبار واستخدام النموذج للتنبؤ استنادا إلى قيمة الميزة (x)؛ ثم مقارنة التسمية المتوقعة (\hat{y}) بالقيمة الفعلية المعروفة (y).

فيؤدي استخدام النموذج الذي دربناه ، الدالة $f(x) = x-50$ ، إلى التنبؤات التالية:

درجة الحرارة (X)	القيمة الفعلية y	القيمة المتوقعة \hat{y}
52	0	2
67	14	17
70	23	20
73	22	23
83	36	28



اتضح وجود بعض التباين بين قيم \hat{y} المحسوبة بواسطة الدالة وقيم y الفعلية من مجموعة بيانات التحقق من الصحة؛ الذي يشار إليه في الرسم كخط بين قيم \hat{y} والتي توضح مدى ابتعاد التنبؤ عن القيمة الفعلية.

مقاييس تقييم الانحدار (التوقع)

استنادا إلى الاختلافات بين القيم المتوقعة والقيم الفعلية، يمكن حساب بعض المقاييس الشائعة المستخدمة لتقييم نموذج الانحدار.

متوسط الخطأ المطلق (MAE)

ولفهم هذا المقياس من خلال المثال السابق يشير التباين إلى عدد القيم التي كان التنبؤ بها خاطئاً. لا يهم ما إذا كان التنبؤ قد تجاوز أو تحت القيمة الفعلية (لذلك على سبيل المثال، يشير كل من $3+$ و $3-$ إلى تباين 3). يعرف هذا المقياس بالخطأ المطلق لكل تنبؤ، ويمكن تلخيصه لمجموعة التحقق الكاملة على أنها متوسط الخطأ المطلق (MAE).

ففي المثال ، متوسط الأخطاء المطلقة (2 و3 و3 و1 و2 و3) هو 14/6 هو 2.33

متوسط خطأ تربيعي (MSE)

يأخذ متوسط مقياس الخطأ المطلق جميع الاختلافات بين التسميات المتوقعة والفعلية في الاعتبار على حد المساواة. ومع ذلك، قد نكون بحاجة إلى تضخيم الأخطاء عن طريق تربيع الأخطاء الفردية وحساب متوسط القيم التربيعية. يعرف هذا المقياس بمتوسط الخطأ التربيعي (MSE)؛ ففي المثال السابق ، متوسط القيم المطلقة التربيعية (وهي 4 و9 و1 و4 و9) هو 6.

جذر متوسط الخطأ التربيعي (RMSE)

يساعد متوسط الخطأ التربيعي في أخذ حجم الأخطاء في الاعتبار، ولكن لأنه يربع قيم الخطأ، فلم يعد المقياس الناتج يمثل الكمية التي تم قياسها. وبعبارة أخرى في المثال السابق كانت قيمة MSE هو 6، ولكن هذا لا يقيس دقة النموذج بل هو مجرد درجة رقمية تشير إلى مستوى الخطأ في تنبؤات التحقق من الصحة.

فإذا أردنا قياس الخطأ ، نحتاج إلى حساب الجذر التربيعي لـ MSE ؛ الذي ينتج مقياساً يسمى خطأ تربيعي متوسط الجذر في هذه الحالة $\sqrt{6}$ ، وهو 2.45.

معامل التحديد (R2)

تقارن جميع المقاييس حتى الآن التناقض بين القيم المتوقعة والقيم الفعلية من أجل تقييم النموذج. ومع ذلك، نجد بعض التباين العشوائي الطبيعي في قيم Y المتوقعة والتي يأخذها النموذج في الاعتبار. في نموذج الانحدار الخطي، تناسب خوارزمية التدريب خطأ مستقيماً يقلل من متوسط التباين بين الدالة وقيم التسمية المعروفة وهو ما يسمى بمعامل التحديد يشار إليه عادة باسم R^2 أو R-Squared وهو مقياس يقيس نسبة التباين في نتائج التحقق من الصحة التي يمكن تفسيرها بواسطة النموذج، بدلاً من بعض الظروف الشاذة التي تؤثر على قيم بيانات التحقق من الصحة (على سبيل المثال، يوم مع عدد غير عادي للغاية من المسافرين بسبب مهرجان محلي).

فحساب R2 أكثر تعقيدا من المقاييس السابقة. حيث يقارن مجموع الاختلافات التربيعية بين التسميات المتوقعة والفعالية مع مجموع الاختلافات التربيعية بين قيم التسمية الفعلية :

$$R2 = 1 - \frac{\sum (y - \hat{y})^2}{\sum (y - \bar{y})^2}$$

∑ سيجمع رمز (جمع كل القيم ضمن نطاق تسلسلي)

إذا كان الأمر يبدو معقدا فلا داعي للقلق لأنه يمكن لمعظم أدوات التعلم الآلي حساب هذه المقاييس ؛ لكن الجدير بالاهمية هو معرفة ان الناتج يتراوح بين 0 و 1 ، كلما اقتربت القيمة من 1 كلما كان النموذج مناسبا لبيانات التحقق من الصحة. ؛ في المثال التطبيقي السابق لنموذج الانحدار يكون R2 المحسوب هو 0.95.

التدريب التكراري

تستخدم المقاييس الموضحة أعلاه عادة لتقييم نموذج الانحدار. في معظم سيناريوهات العالم الحقيقي، سيستخدم عالم البيانات عملية تكرارية لتدريب نموذج وتقييمه بشكل متكرر وفقا لما يلي:-

- تحديد الميزات وإعدادها (اختيار الميزات التي يجب تضمينها في النموذج، والحسابات المطبقة عليها للمساعدة في ضمان ملاءمة أفضل).
- تحديد الخوارزمية (ذكرنا الانحدار الخطي في المثال السابق، ولكن هناك العديد من خوارزميات الانحدار الأخرى)
- معلمات الخوارزمية (إعدادات رقمية للتحكم في سلوك الخوارزمية، وتسمى بدقة المعلمات الفائقة لتمييزها عن المعلمات x و y).

بعد تكرارات متعددة، يتم تحديد النموذج الذي ينتج عنه أفضل مقياس تقييم مقبول للسيناريو المحدد.

ثانياً:- التصنيف Classification

يعتبر التصنيف مثل الانحدار، في كونه أسلوب تعلم آلي خاضع للإشراف؛ وبالتالي يتبع نفس العملية التكرارية لتدريب النماذج والتحقق من صحتها وتقييمها. لكن في التصنيف بدلا من حساب القيم الرقمية كما في نموذج الانحدار، تحسب الخوارزميات المستخدمة لتدريب نماذج التصنيف قيم الاحتمال لتعيين الفئة ومقاييس التقييم المستخدمة لتقييم أداء النموذج مقارنة الفئات المتوقعة بالفئات الفعلية.

سبق ان ذكرنا ان هناك صور مختلفة للتصنيف الا وهى التصنيف الثنائى والتصنيف المتعدد وفيما يلي توضيح كل منهما على حدى:

1- التصنيف الثنائي

تستخدم خوارزميات التصنيف الثنائي لتدريب نموذج يتنبأ بأحد التسميات المحتملة لفئة واحدة. بحيث يكون التنبؤ إما ب True أو False (القيم حقيقية أم خاطئة) ففي معظم السيناريوهات تتكون البيانات المستخدمة لتدريب النموذج والتحقق من صحته من قيم مميزة متعددة (x) وقيمة y تكون بين قيمتين إما 1 أو 0

مثال تطبيقي (التصنيف الثنائي)

لفهم كيفية عمل التصنيف الثنائي، دعونا ننظر إلى مثال مبسط يستخدم ميزة واحدة (x) للتنبؤ بما إذا كانت قيم y هي 1 أو 0 ؛ فمثلا لدينا قيم لتحليل نسبة الجلوكوز لعدد من المرضى ؛ وبناء عليها يتم توقع اذا كان المريض مصاب بداء السكر (1) ام لاء (0)

بيانات الاختبار

احتمالية المرض	نسبة الجلوكوز
0	66
1	107
1	112
0	71
1	87
1	89
0 = غير مريض	
1 = مريض	


بيانات التدريب

نسبة الجلوكوز (X)	احتمالية المرض الفعلية (y)
67	0
103	1
114	1
72	0
116	1
65	0
0 = غير مريض	
1 = مريض	

تدريب نموذج التصنيف الثنائي:

لتدريب النموذج، نستخدم خوارزمية لملاءمة بيانات التدريب مع دالة تحسب احتمال صحة التوقع حيث يتم قياس الاحتمال كقيمة بين 0.0 و 1.0، بحيث يكون الاحتمال الإجمالي لجميع الفئات المحتملة هو 1.0. على سبيل المثال، إذا كان احتمال الحالة مصابة بالمرض 0.7، فهناك احتمال مقابله يبلغ 0.3 أن الحالة ليست مصابة بالمرض .

هناك العديد من الخوارزميات التي يمكن استخدامها للتصنيف الثنائي، منها الانحدار اللوجستي، الذي يستمد دالة sigmoid على شكل (S) مع قيم بين 0.0 و 1.0، مثل هذا:



ملاحظة:

النقطة المهمة هنا في هذه الخوارزمية هي الطبيعة اللوجستية للدالة التي تنتجها، والتي تصف منحنى على شكل S بين القيمة الدنيا والأعلى (0.0 و 1.0 عند استخدامها للتصنيف الثنائي).

يمكن استخدام الدالة الرياضية التي تنتجها الخوارزمية في هذه الحالة (احتمال صحة $(y=1)$ لقيمة معينة من x) على النحو التالي :

$$f(x) = P(y=1 | x)$$

P : تشير الى الاحتمالية بناء على شرط محدد .


| : تعبر عن معطوف على؛ تُستخدم هذه العلامة لتحديد الشرط الذي يجب أن يتوفر في البيانات حتى يتم حساب الاحتمالية المرتبطة بهذا الشرط.

ففي الجدول السابق نجد ان هناك ثلاث قيم من القيم الست في بيانات التدريب، قيمة (y) فيها صحيح بالتأكيد، لذا فإن احتمال أن تكون $y=1$ هي 1.0 وبالنسبة للملاحظات الثلاث الأخرى، نعلم أن (y) بالتأكيد خطأ، لذا فإن احتمال أن $y=1$ هو 0.0. يصف المنحنى على شكل S توزيع الاحتمال بحيث يحدد رسم قيمة x على السطر الاحتمال المقابل وهو y هو 1.

ويتضمن الرسم التخطيطي أيضا خطا أفقيا للإشارة إلى الحد الذي سيتنبأ به النموذج المستند إلى هذه الدالة بالقيمة (1) true أو (0) false يقع الحد عند نقطة الوسط لـ $(P(y) = 0.5)$ فبالنسبة لأي قيم في هذه المرحلة أو أعلى، سيتنبأ النموذج بالقيمة (1)؛ بينما بالنسبة لأي قيم أسفل هذه النقطة، فإنه سيتنبأ بالخطأ (0) على سبيل المثال، بالنسبة للمريض الذي لديه مستوى جلوكوز 90، ستؤدي الدالة إلى قيمة احتمالية تبلغ 0.9. نظرا لأن 0.9 أعلى من عتبة 0.5، فإن النموذج يتوقع صواب (1) ويتوقع أن يكون المريض مصابا بداء السكر.

تقييم نموذج التصنيف الثنائي:

بنفس طريقة تقييم نموذج الانحدار يتم اختيار مجموعة فرعية عشوائية من البيانات للتحقق من صحة النموذج المدرب. وتطبيق الدالة على بيانات الاختبار كما موضح بالشكل التالي



بناء على ما إذا كان الاحتمال المحسوب بواسطة الدالة أعلى من الحد أو أقل منه، ينشئ النموذج تسمية متوقعة من 0 أو 1 لكل ملاحظة. يمكننا بعد ذلك مقارنة تسميات الفئة المتوقعة (\hat{y}) بتسميات الفئة الفعلية (y)، كما هو موضح:

نسبة الجلوكوز (X)	احتمالية المرض الفعلية (y)	احتمالية المرض المتوقعة (\hat{y})
66	0	0
107	1	1
112	1	1
71	0	0
87	1	0
89	1	1

مقاييس تقييم التصنيف الثنائي:

الجدير بالذكر أنه في اغلبية الاحوال تكون الخطوة الأولى في حساب مقاييس التقييم لنموذج التصنيف الثنائي هي إنشاء مصفوفة لعدد التنبؤات الصحيحة وغير الصحيحة لكل تسمية فئة ممكنة (مصفوفة الارتباك) حيث تظهر إجماليات التنبؤ على النحو الموضح

		Positive	Negative		
		True Positive (TP)	False Positive (FP)		
الصفة المتوقعة Predicted Label	Positive	True Positive (TP)	False Positive (FP)		
	Negative	False Negative (FN)	True Negative (TN)		
		True Label الصفة الحقيقية			

فمصفوفة الارتباك هي جدول يلخص أداء نموذج التصنيف. على سبيل المثال ، تعرض مصفوفة الإرباك عدد الإيجابيات الصحيحة والسلبيات الصحيحة و الإيجابيات الخاطئة و السلبيات الخاطئة. من ناحية أخرى تعد هذه المصفوفة مفيدة لتصوير أداء النموذج وتحديد مجالات التحسين.

		\hat{y}	
		0	1
Y	0	2	0
	1	1	3

- $y=0; \hat{y}=0$ السلبيات الحقيقية (TN)
- $y=0; \hat{y}=1$ الإيجابيات الخاطئة (FP)
- $y=1; \hat{y}=0$ السلبيات الخاطئة (FN)
- $y=1; \hat{y}=1$ الإيجابيات الحقيقية (TP)

الدقة: Accuracy

أبسط مقياس يمكنك حسابه من مصفوفة الارتباك هو الدقة أى نسبة التنبؤات التي حصل عليها النموذج بشكل صحيح. يتم حساب الدقة على النحو التالي:

$$(TN+TP) \div (TN+FN+FP+TP)$$

في حالة المثال السابق (نسب الجلوكوز) ، فإن الحساب هو:

$$(2+3) \div (2+1+0+3)$$

$$= 5 \div 6$$

$$= 0.83$$

أى أن النموذج وصلت نسبة التنبؤات الصحيحة به إلى 83%.

لكن هذا المقياس غير دقيق ففى نفس المثال لو أن هناك نسبة محددة من السكان 10% مصابون بالمرض فيمكن إنشاء نموذج يتنبأ دائماً ب 0، وسيحقق دقة 90%، على الرغم من أنه لا يقوم بمحاولة حقيقية للتمييز بين المرضى لذا فما نحتاجه حقا هو فهم أعمق لكيفية أداء النموذج عند التنبؤ ب 1 للحالات الإيجابية و 0 للحالات السلبية.

الاستدعاء أو الاسترجاع Recall :

هو مقياس يقيس نسبة الحالات الإيجابية التي حددها النموذج بشكل صحيح. أى مقارنة عدد المرضى الذين يعانون من مرض السكر، بأعداد الذين توقع النموذج الإصابة بهم.

دالة الاستدعاء هي:

$$TP \div (TP+FN)$$

وبالتطبيق على المثال السابق:

$$3 \div (3+1)$$

$$= 3 \div 4$$

0.75 = أى أن دقة النموذج تساوى 0.75

الانضباط Precision

هي مقياس يقيس نسبة الحالات الإيجابية المتوقعة حين تكون التسمية الحقيقية إيجابية بالفعل. وبعبارة أخرى، ما هي نسبة المرضى الذين توقعهم النموذج لمرض السكر بالفعل؟

دالة الانضباط هي:

$$TP \div (TP+FP)$$

وبالتطبيق :

$$3 \div (3+0)$$

$$= 3 \div 3$$

$$= 1.0$$

لذا فإن 100٪ من المرضى الذين توقعهم نموذجنا لمرض السكري لديهم بالفعل مرض السكري.

درجة F1:

هي المتوسط التوافقي للدقة و الاستدعاء. ، تعتبر درجة F1 مقياس شائع الاستخدام عندما يكون كل من الدقة والاستدعاء مهمين يتم حساب درجة F1 على النحو التالي:

$$(2 \times Precision \times Recall) \div (Precision + Recall)$$

وبالتطبيق على الامثلة السابقة =

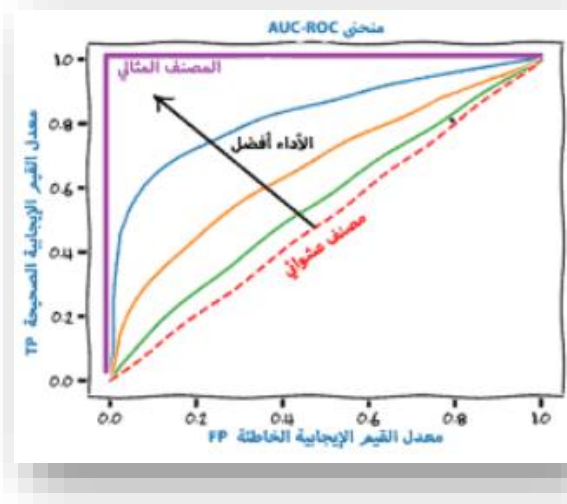
$$(2 \times 1.0 \times 0.75) \div (1.0 + 0.75)$$

$$= 1.5 \div 1.75$$

$$= 0.86$$

المنطقة تحت المنحنى (AUC):

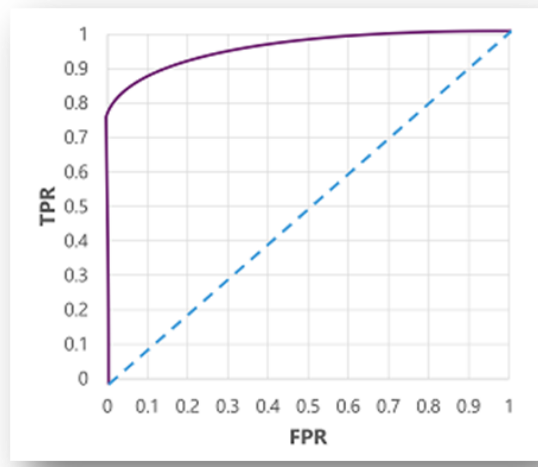
وتسمى أيضا بالمعدل الإيجابي الحقيقي (TPR)، وهناك مقياس مكافئ يسمى المعدل الإيجابي الخاطئ (FPR) الذي يتم حسابه على النحو التالي $FP \div (FP+TN)$



و بتطبيق TPR على نموذجنا عند استخدام حد 0.5 هو 0.75، ويمكننا استخدام صيغة FPR

$$2 \div 0 = 0$$

وبطبيعة الحال، إذا أردنا تغيير الحد الذي يتنبأ به النموذج أعلاه بالقيمة الحقيقية (1)، فإنه سيؤثر على عدد التنبؤات الإيجابية والسلبية؛ وبالتالي سيغير مقاييس (TPR) و (FPR). غالباً ما تستخدم هذه المقاييس لتقييم نموذج عن طريق رسم منحنى (ROC) الذي يقارن TPR و FPR لكل قيمة حد ممكنة بين 0.0 و 1.0



في حالة نموذج مرض السكري لدينا، يتم إنتاج المنحنى أعلاه، والمساحة تحت مقياس المنحنى (AUC) هي 0.875. نظرا لأن AUC أعلى من 0.5، يمكننا استنتاج أن أداء النموذج أفضل في التنبؤ بما إذا كان المريض مصابا بالسكري أم لا من التخمين العشوائي.

2- التصنيف متعدد الفئات:

يستخدم التصنيف متعدد الفئات للتنبؤ بفئات متعددة محتملة. كأسلوب تعلم آلي خاضع للإشراف، فإنه يتبع نفس عملية التدريب التكراري والتحقق من صحته وتقييمه على أنها تراجع وتصنيف ثنائي حيث يتم الاحتفاظ بمجموعة فرعية من بيانات التدريب مرة أخرى للتحقق من صحة النموذج المدرب. تختلف خوارزميات التصنيف متعددة الفئات عن التصنيف الثنائي في انها تستخدم الاحتمال لتسميات فئات متعددة.

مثال تطبيقي :

حيث لدينا بعض البيانات التي تعكس لنا انواع القطط ، حيث يتم التعرف على نوع القطة من خلال طولها (x) وهناك ثلاثة انواع من القطط حسب الاطوال الموجودة في البيانات (Y) لتكون تلك الانواع على النحو التالي :

0: قط شرقي

1 : قط بيكسي

2: قط شرزي

النوع (Y)	طول القطة (X)
0	167
0	172
2	225
1	197
1	189
2	232
0	158

تدريب النموذج تصنيف متعدد الفئات

لتدريب نموذج تصنيف متعدد الفئات، نحتاج إلى استخدام خوارزمية لاحتواء بيانات التدريب مع دالة تحسب قيمة احتمالية لكل فئة. هناك نوعان من الخوارزميات التي يمكن استخدامها للقيام بذلك:

- خوارزميات (OvR) One-vs-Rest
- خوارزميات متعددة الحدود.

خوارزميات (OvR) One-vs-Rest

تقوم خوارزميات One-vs-Rest بتدريب دالة تصنيف ثنائي لكل فئة، كل منها يحسب احتمال أن تكون الملاحظة مثالا على الفئة المستهدفة. ففي المثال تقوم الخوارزمية بإنشاء ثلاث وظائف تصنيف ثنائية:

- $f_0(x) = P(y=0 | x)$
- $f_1(x) = P(y=1 | x)$
- $f_2(x) = P(y=2 | x)$

تنتج كل خوارزمية دالة sigmoid تحسب قيمة احتمالية بين 0.0 و 1.0. يتنبأ النموذج المدرب باستخدام هذا النوع من الخوارزمية بفئة الدالة التي تنتج .

خوارزميات متعددة الحدود

حيث تنشئ دالة واحدة ترجع قيم متعددة . الإخراج هو متجه (مجموعة من القيم) يحتوي على توزيع الاحتمال لجميع الفئات المحتملة - مع درجة الاحتمال لكل فئة والتي عند إجمالها تضيف ما يصل إلى 1.0:

$$f(x) = [P(y=0|x), P(y=1|x), P(y=2|x)]$$

مثال على هذا النوع من الدالة هو دالة softmax، والتي يمكن أن تنتج إخراجا مثل المثال التالي:

$$[0.2, 0.3, 0.5]$$

تمثل العناصر الموجودة في المتجه احتمالات الفئات 0 و 1 و 2 على التوالي؛ لذلك في هذه الحالة، الفئة ذات الاحتمال الأعلى هي 2.

بغض النظر عن نوع الخوارزمية المستخدمة، يستخدم النموذج الدالة الناتجة لتحديد الفئة الأكثر احتمالاً لمجموعة معينة من الميزات (x) ويتنبأ بتسمية الفئة المقابلة (y).

تقييم نموذج تصنيف متعدد الفئات

يمكن تقييم النموذج عن طريق حساب مقاييس التصنيف الثنائي لكل فئة فردية. أو من خلال حساب المقاييس الإجمالية التي تأخذ جميع الفئات في الاعتبار.

فلو أننا تحققنا من صحة المصنف متعدد الفئات، وحصلنا على النتائج التالية:

الأنواع المتوقعة (ŷ)	الأنواع الفعلية (y)	طول القطط (x)
0	0	165
0	0	171
1	2	205
1	1	195
1	1	183
2	2	221
2	2	214

تشبه مصفوفة الارتباك لمصنف متعدد الفئات مصفوفة المصنف الثنائي، باستثناء أنها تعرض عدد التنبؤات لكل مجموعة من التسميات/المتوقعة (ŷ) والفئة الفعلية (y)

		\hat{y}		
		0	1	2
Y	0	2	0	0
	1	0	2	0
	2	0	1	2

من مصفوفة الارتباك هذه، يمكننا تحديد المقاييس لكل فئة فردية على النحو التالي:

الاسترجاع	الدقة الإجمالية	F1-Score	الدقة	FN	Fp	TN	Tp	الفئة
1.0	1.0	1.0	1.0	0	0	5	2	0
1.0	0.67	0.8	0.86	0	1	4	2	1
0.67	1.0	0.8	0.86	1	0	4	2	2

لحساب مقاييس الدقة والاستدعاء والدقة الإجمالية، يمكنك استخدام إجمالي مقاييس TP وTN وFP وFN

- الدقة الإجمالية $= (13+6) \div (13+6+1+1) = 0.90$
- الاستدعاء الإجمالي $= 6 \div (6+1) = 0.86$
- الدقة $= 6 \div (6+1) = 0.86$

يتم حساب درجة F1 الإجمالية باستخدام مقاييس الاستدعاء والدقة الإجمالية:

$$1 \text{ F1} = (2 \times 0.86 \times 0.86) \div (0.86 + 0.86) = 0.86$$

التعلم الآلي غير خاضع للإشراف Unsupervised machine learning:


على عكس التعلم الموجّه، الآلة تُعطى بيانات وتتعلم من نفسها عن طريق محاولة إيجاد أنماط (Patterns)، يتم ذلك عن طريق تجميع (Clustering) البيانات التي لدينا إلى مجموعات حسب ما تشابه فيه. مثال على ذلك: عندما يكون لدينا بيانات كثيره عن منازل في مدينة معينة، نقوم بتقسيمها (Clustering) حسب العنوان أو الحي الذي تتواجد فيه .

التجميع (Clustering) :

التجميع هو شكل من أشكال التعلم الآلي غير الخاضع للإشراف حيث يتم تجميع البيانات في مجموعات استنادا إلى أوجه التشابه في قيم البيانات أو الميزات الخاصة بها. يعتبر هذا النوع من التعلم الآلي غير خاضع للإشراف لأنه لا يستخدم قيم التسمية (Y) المعروفة سابقا لتدريب نموذج. في نموذج تكوين أنظمة المجموعات، تكون التسمية هي المجموعة التي يتم تعيين الملاحظة إليها، استنادا فقط إلى ميزاتها.

مثال : تكوين أنظمة المجموعات

على سبيل المثال، لنفترض أن عالم النبات يراقب عينة من الزهور ويسجل عدد الأوراق والبتلات على كل زهرة:

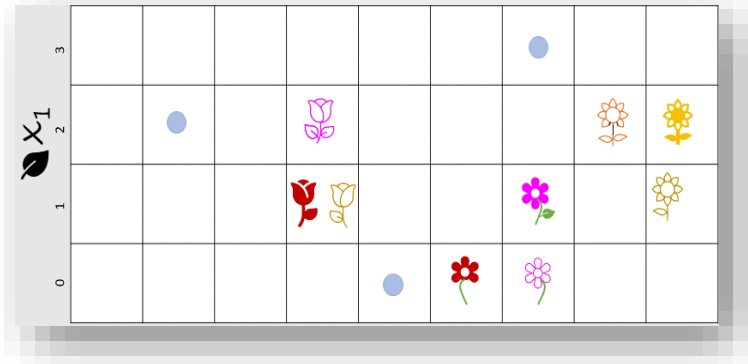


عدد الاوراق (x1)	البتلات (x2)
0	5
0	6
1	3
1	3
1	6
1	8
2	3
2	7
2	8

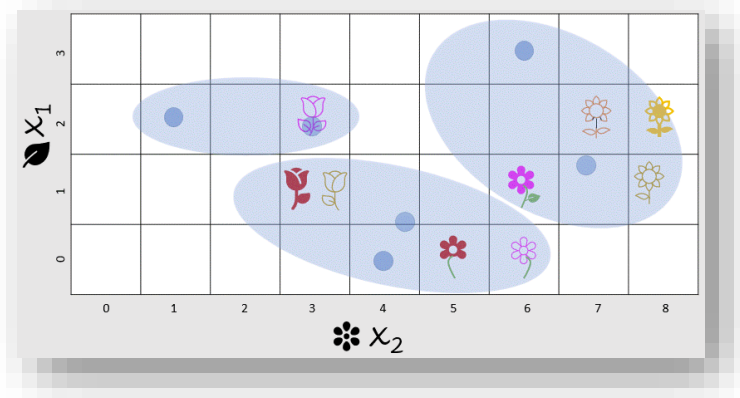
تدريب النموذج :

هناك العديد من الخوارزميات التي يمكن استخدامها لتكوين أنظمة المجموعات. إحدى أكثر الخوارزميات استخدامًا هي خوارزميات K-Means لتكوين أنظمة المجموعات، وذلك على النحو التالي :


1. يتم تحويل قيم الميزة (x) لتحديد إحداثيات الأبعاد n (حيث n هو عدد الميزات). ففي المثال السابق، لدينا ميزتان هما عدد الأوراق (x_1) وعدد البتلات (x_2). لذلك، يحتوي متجه الميزة على إحداثيتين يمكننا استخدامها لرسم نقاط البيانات ($[x_1, x_2]$).
2. تحديد عدد المجموعات التي نريد استخدامها لتجميع الزهور (استدعاء هذه القيمة k) على سبيل المثال، لإنشاء ثلاث مجموعات، يمكن استخدام قيمة k وهي 3.
3. يتم رسم نقاط في إحداثيات عشوائية. تصبح هذه النقاط النقاط المركزية لكل نظام مجموعة، لذلك تسمى النقاط المركزية.



4. يتم تعيين كل نقطة بيانات (زهرة) إلى أقرب مركزية لها.



5. يتم نقل كل نقطة مركزية إلى مركز نقاط البيانات المعينة لها استنادًا إلى متوسط المسافة بين النقاط.
6. تتكرر خطوات الحركة المركزية وإعادة تخصيص نظام المجموعة حتى تصبح المجموعات مستقرة أو يتم الوصول إلى الحد الأقصى المحدد مسبقًا لعدد التكرارات.



تقييم النموذج :

نظرا لعدم وجود تسمية معروفة لمقارنة تعيينات نظام المجموعة المتوقعة بها، فإن تقييم النموذج هنا يستند إلى مدى فصل المجموعات الناتجة عن بعضها البعض.

هناك مقاييس متعددة يمكن استخدامها لتقييم فصل نظام المجموعة، منها على سبيل المثال لا الحصر:

- متوسط المسافة إلى مركز نظام المجموعة: مدى قرب كل نقطة في نظام المجموعة في المتوسط من النقطة المركزية للمجموعة.
- متوسط المسافة إلى مركز آخر: مدى قرب كل نقطة في نظام المجموعة في المتوسط من النقطة المركزية لجميع المجموعات الأخرى.
- الحد الأقصى للمسافة إلى مركز نظام المجموعة: أبعد مسافة بين نقطة في نظام المجموعة ومركزها.
- صورة ظليلة: قيمة بين 1- و 1 وهي نسبة المسافة بين النقاط في نفس المجموعة والنقاط في مجموعات مختلفة (كلما اقتربت من 1، كان فصل نظام المجموعة أفضل).

تخفيض الأبعاد Dimensionality Reduction:

تقليل أو تخفيض الأبعاد هو عملية تقليل عدد الميزات في مجموعة البيانات مع الاحتفاظ بأكبر قدر ممكن من المعلومات. يمكن القيام بذلك لعدة أسباب، مثل تقليل تعقيد النموذج، أو تحسين أداء خوارزمية التعلم، أو تسهيل تصور البيانات.

هناك العديد من التقنيات لتقليل الأبعاد، بما في ذلك تحليل المكون الرئيسي (PCA)، وتحليل القيمة المفردة (SVD)، والتحليل التمييزي الخطي (LDA). تستخدم كل تقنية طريقة مختلفة لعرض البيانات على مساحة ذات أبعاد أقل مع الحفاظ على المعلومات المهمة.

هناك طريقتان رئيسيتان لتقليل الأبعاد:

اختيار الميزة:

يتضمن اختيار الميزة تحديد مجموعة فرعية من الميزات الأصلية الأكثر صلة بالمشكلة المطروحة. الهدف هو تقليل أبعاد مجموعة البيانات مع الاحتفاظ بالميزات الأكثر أهمية. هناك عدة طرق لاختيار الميزة، منها التصفية، و التغليف، والأساليب المضمنة .

التصفية : تقوم طرق التصفية بترتيب الميزات بناءً على مدى صلتها بالمتغير المستهدف

التغليف : تستخدم طرق التغليف أداء النموذج كمعيار لاختيار الميزات.

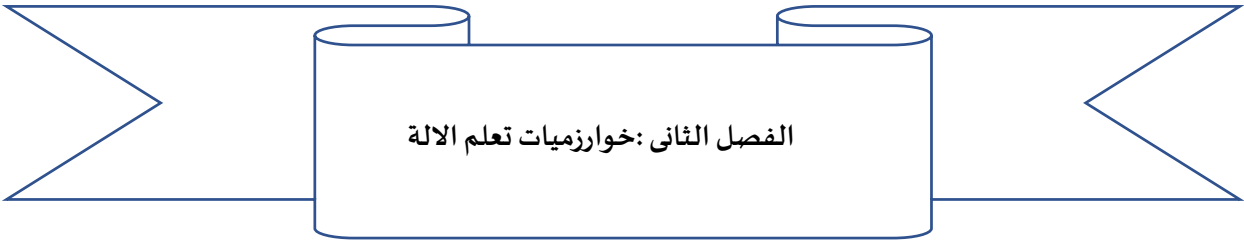
الطرق المضمنة :تجمع الطرق المضمنة بين اختيار الميزات وعملية تدريب النموذج.

استخراج الميزات:

يتضمن استخراج الميزات إنشاء ميزات جديدة من خلال دمج الميزات الأصلية أو تحويلها. الهدف هو إنشاء مجموعة من الميزات التي تجسد جوهر البيانات الأصلية في مساحة ذات أبعاد أقل. هناك عدة طرق لاستخراج الميزات، منها تحليل المكونات الرئيسي (PCA) ، والتحليل التمييزي الخطي (LDA) ، وتضمين الجوار العشوائي الموزع PCA (t-SNE) .

مثال لتخفيض الأبعاد :

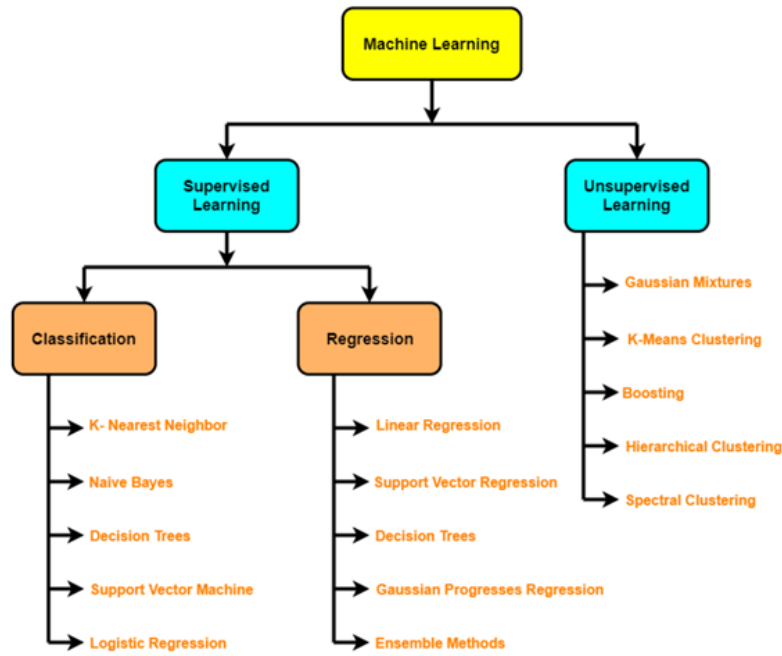
يمكن مناقشة مثال لتقليل الأبعاد من خلال مشكلة تصنيف البريد الإلكتروني البسيطة، حيث نحتاج إلى تصنيف ما إذا كان البريد الإلكتروني بريدًا عشوائيًا أم لا. يمكن أن يتضمن ذلك عددًا كبيرًا من الميزات، مثل هل البريد الإلكتروني له عنوان عام أم لا، ومحتوى البريد الإلكتروني، وما إذا كان البريد الإلكتروني يستخدم قالبًا، وما إلى ذلك. ومع ذلك، قد تتداخل بعض هذه الميزات . فيمكننا تقليل عدد الميزات في مثل هذه المشاكل.



الفصل الثاني: خوارزميات تعلم الآلة

خوارزميات تعلم الآلة:

تُعد خوارزميات تعلم الآلة أداة قوية للتعامل مع تحليل البيانات واستخراج الأنماط الضخمة وتحسين القرارات في مجموعة متنوعة من المجالات وهناك العديد من الأنواع المختلفة لخوارزميات تعلم الآلة وفقاً لنوع تعلم الآلة المستخدم وذلك على النحو الموضح بالشكل أدناه



شجرة اختيار الخوارزمية المناسبة :

شجرة اختيار الخوارزمية هي طريقة توجيهية تستخدم لاختيار الخوارزمية المناسبة لمشكلة معينة في مجال التعلم الآلي. تُستخدم هذه الشجرة لتوجيه المهندس أو المُطور إلى الخوارزمية الأنسب استنادًا إلى خصائص المشكلة والبيانات. وفيما يلي شرحًا لكيفية استخدام شجرة اختيار الخوارزمية:

الخطوة الأولى: تحديد نوع المشكلة التي نحاول حلها، مثل التصنيف، أو التنبؤ، أو التجميع، إلخ.
الخطوة الثانية: تحليل خصائص البيانات المتاحة، مثل حجمها، ونوعها (رقمي، تصنيفي، إلخ)، وتوزيعها.

الخطوة الثالثة: اختيار المعيار الأساسي بناءً على نوع المشكلة وخصائص البيانات، يتم اختيار المعيار الأساسي للتقييم، مثل الدقة، أو المتوسط الحسابي للخطأ، أو معامل F1.

الخطوة الرابعة: اختيار الخوارزمية المبدئية المناسبة استناداً إلى المعيار الأساسي المحدد.

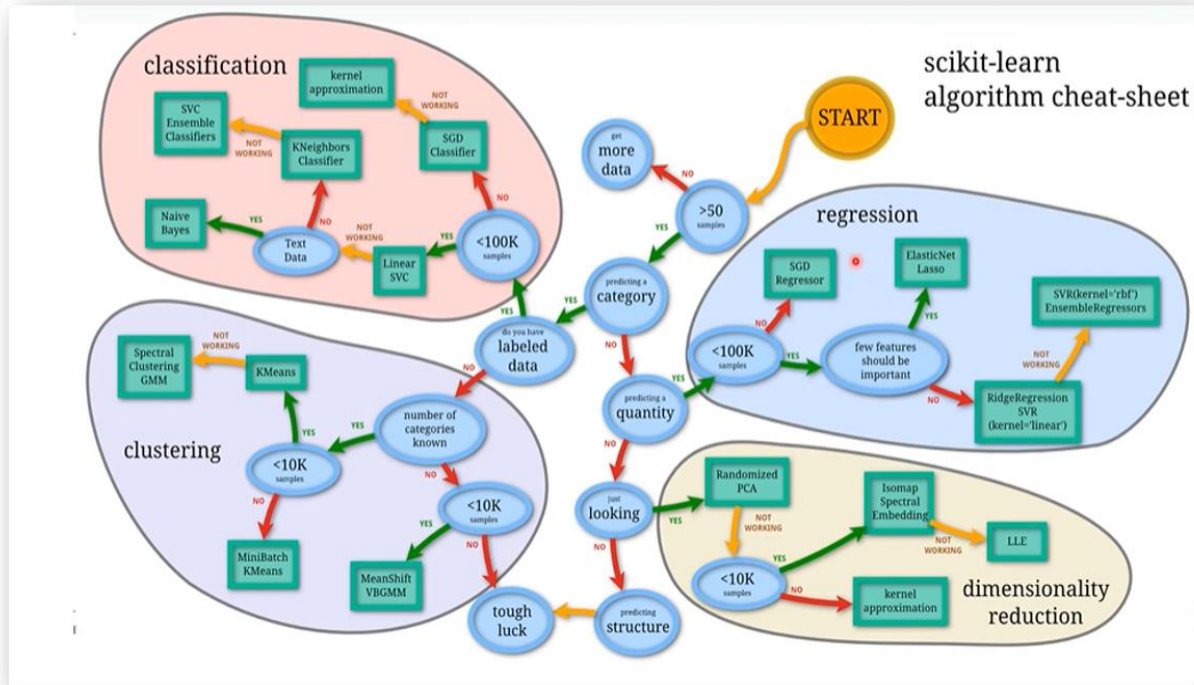
الخطوة الخامسة: تقييم الخوارزميات المبدئية باستخدام المعيار الأساسي المحدد.

الخطوة السادسة: اختيار الخوارزمية النهائية التي تحقق أفضل أداء بناءً على التقييم.

الخطوة السابعة: تحسين وتعديل الخوارزمية المختارة عن طريق تعديل معلماتها أو تطبيق تقنيات تحسين الأداء.

الخطوة الثامنة: التحقق والتقييم النهائي حيث يتم التحقق من أداء الخوارزمية المحسنة على بيانات اختبار مستقلة وتقييم أدائها النهائي.

من خلال هذه الخطوات، يمكن للمطورين أو المهندسين في مجال التعلم الآلي اختيار وتحسين الخوارزمية المناسبة بشكل فعال لحل المشكلة المعينة.




خوارزميات التعلم الاشرافي (التصنيف Classification)

1- الانحدار اللوجستي Logistic Regression

إحدى خوارزميات تعلم الآلة وأشهر خوارزميات التصنيف (Classification) وتستخدم لتصنيف البيانات إلى فئات (Classes) منفصلة والانحدار اللوجستي هو انحدار يعتمد على الدالة السينية (Sigmoid Function) ونواتجها تنحصر بين الصفر والواحد.

$$S(x) = \frac{1}{1+e^{-x}}$$

خوارزمية الانحدار اللوجستي تقسم البيانات إلى مجموعتين متناقضتين ولا ينفع استخدام هذه الخوارزمية إلا إذا كانت مجموعة بيانات التدريب مصنفة إلى صنفين فقط. مثل: ذكر وأنثى أو نعم لا، أو ناجح راسب.



Logistic Regression
الانحدار اللوجستي

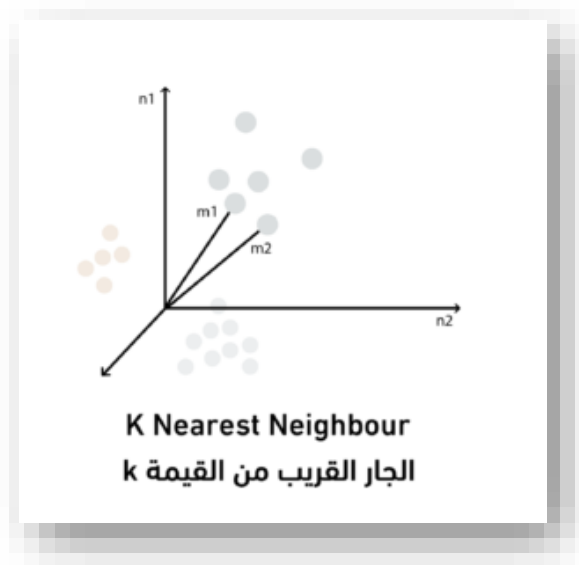
2- خوارزمية الجار الأقرب k-Nearest Neighbors

- تعتبر خوارزمية الجار الأقرب من خوارزميات تعلم الآلة ضمن مجموعة التعلم تحت إشراف، والتي تعدّ "من أبسط الخوارزميات نظراً لسهولة استخدامها واستهلاكها للقليل من الوقت.

- تستخدم خوارزمية الجار الأقرب KNN مجموعة البيانات بأكملها كمجموعة تدريب بدلاً من تقسيم مجموعة البيانات إلى مجموعة تدريب واختبار، لأنّ خوارزمية الجار الأقرب تعمل على فصل بيانات مصنّفة مسبقاً.
- تنتقل خوارزمية الجار الأقرب KNN عبر مجموعة البيانات بأكملها للعثور على أقرب مثيلات k إلى العنصر الجديد
- قيمة k يحددها المستخدم.
- يتمّ حساب التشابه بين الحالات باستخدام مقياس مثل مقياس المسافة الإقليدية ومسافة هامينج.



كيفية عمل خوارزمية الجار الأقرب KNN



تم قياس المسافات بين كل قيمة من قيم k ، عن طريق معادلات المسافة الرياضية، وأشهر معادلة قياس مسافة هي معادلة المسافة الإقليدية. (Euclidean Distance).

$$d(y, x) = \sqrt{(y_1 - x_1)^2 + (y_2 - x_2)^2 + \dots + (y_n - x_n)^2}$$

$$= \sqrt{\sum_{i=1}^n (y_i - x_i)^2}$$

دالة المسافة الإقليدية

تقيس الدالة الإقليدية المسافة بين نقطتين، حيث أن P و Q هما مجموعتين مختلفتين، ويتم تطبيق هذا القانون على جميع النقاط في العينة لنرى أي نقطة أقرب لكل مجموعة على اعتقاد أن المجموعة الأولى هي $K=1$ أو المجموعة ألف، والمجموعة الثانية هي $K=2$ أو المجموعة باء.

ولكن ستواجهنا مشكلة وهي أنه ستكون هنالك قيم ستكون بعيدة عن جميع المجموعات ولذلك سنلجأ لخوارزمية SVM لحل هذه المشكلة.

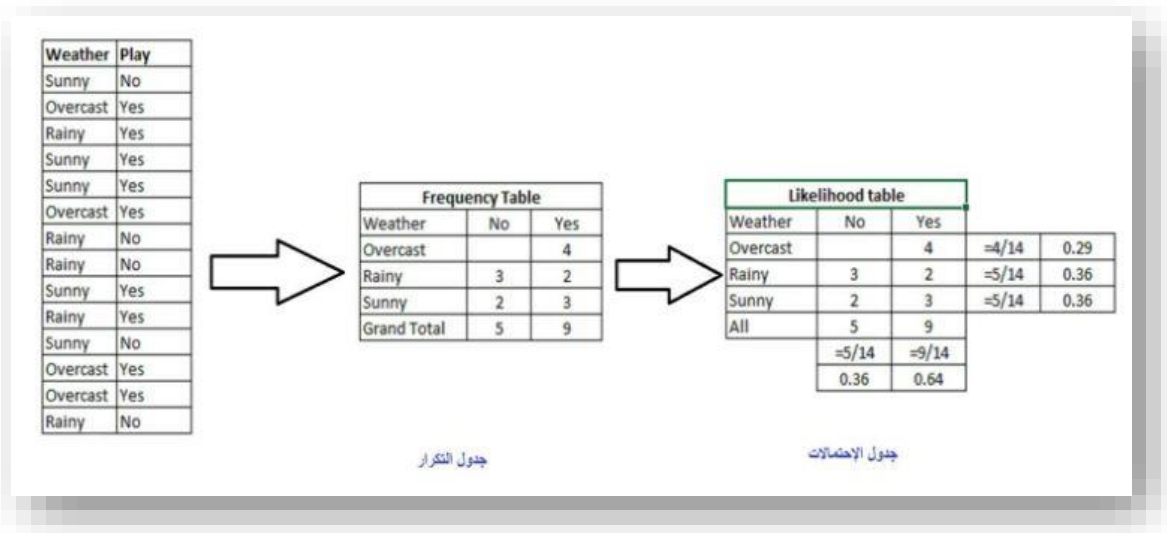
3- خوارزمية المصنّف البايزي الساذج Naive Bayes classifier

هي طريقة تصنيف تعتمد على نظرية بايز، تبدو Naive Bayes خوارزمية شاقّة لأنّها تتطلّب معرفة رياضيّة أوليّة في الاحتمال الشرطيّ و نظريّة بايز لكنّها كمفهوم سهلة للغاية .

بفرض لدينا المتغيّر X الذي يعبر عن شخص سيلعب كرة قدم بناءً على حالة الطّقس، لدينا حالات الطّقس وأمام كلّ حالة المتغيّر الهدف الذي سيأخذ نعم سيلعب أو لا .

هناك ثلاث خطوات لتجهيز الخوارزمية للتنبؤ فيما إذا كان X سيلعب أو لا .

جمع البيانات - حساب جدول التكرار - حساب جدول الاحتمالات



بعد ذلك نستخدم معادلة Naive Bayesian لحساب احتمال حدوث كلّ فئة (Class)، في مثالنا هناك فئتان (Yes/No) والاحتمال الأعلى هو نتيجة التنبؤ.

$$P(c|x) = \frac{P(x|c)P(c)}{P(x)}$$

احتمالية ←
 فئة الاحتمال المسبق ↑
 ↓ الاحتمال المعكوس
 توقع الاحتمال المسبق

$$P(c|X) = P(x_1|c) \times P(x_2|c) \times \dots \times P(x_n|c) \times P(c)$$

لنختبر الفرضية التالية: (Hypothesis) سيلعب X إذا كان الطقس مشمساً، هل هذه الفرضية صحيحة؟ نحتاج إلى حساب حدوث نعم (Class) مع خاصية مشمس. (Feature).

$$P(\text{مشمس} | \text{نعم}) = P(\text{نعم} | \text{مشمس}) * P(\text{نعم}) / P(\text{مشمس})$$

بالرجوع إلى جدول الاحتمالات نجد

جدول الإحتمالات

Likelihood table			
Weather	No	Yes	
Overcast		4	=4/14 0.29
Rainy	3	2	=5/14 0.36
Sunny	2	3	=5/14 0.36
All	5	9	
	=5/14	=9/14	
	0.36	0.64	

المطلوب حساب P (yes | sunny)
احتمالية أن تكون (نعم) مع خاصية (شمس)
يعني أنه سيلعب أحمد إن كان الطقس مشمس

P(sunny) = 0.36

P(yes) = 0.64

P(sunny | yes) = 3 / 9 = 0.33

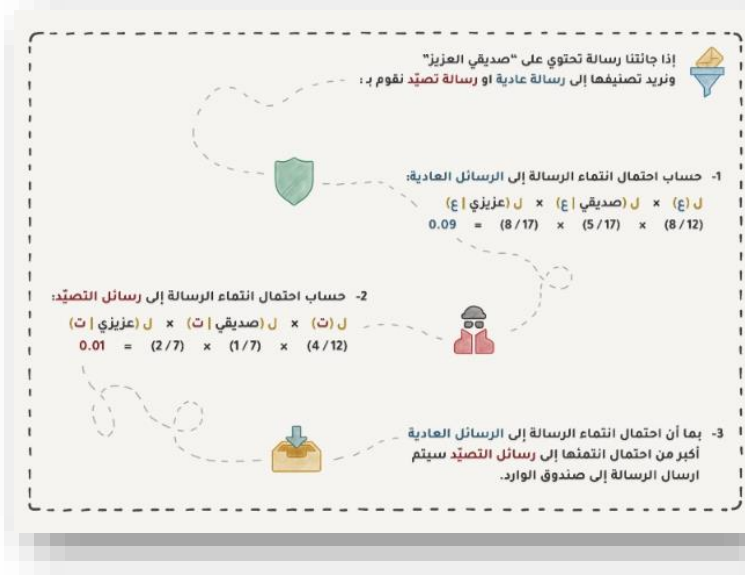
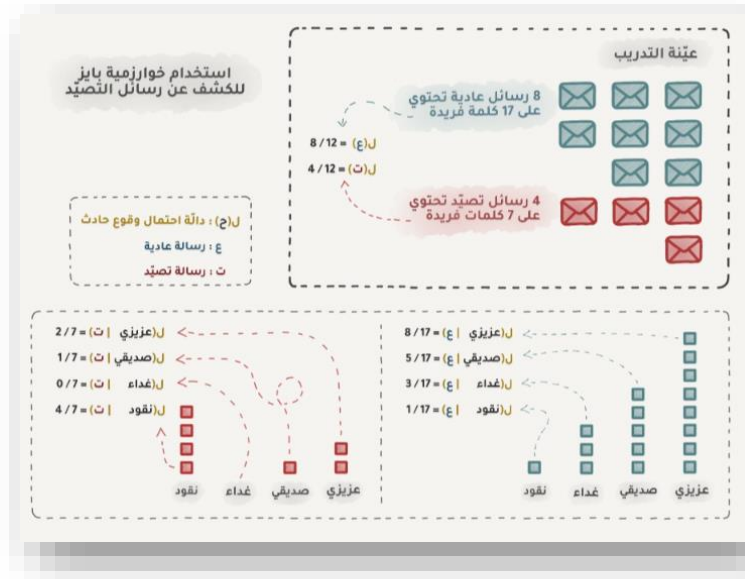
$$P(\text{sunny} | \text{yes}) = 0.33$$

$$P(\text{yes}) = 0.64$$

$$P(\text{sunny}) = 0.36$$

ونتيجة المعادلة 0.59 لذا فإن الفرضية صحيحة.

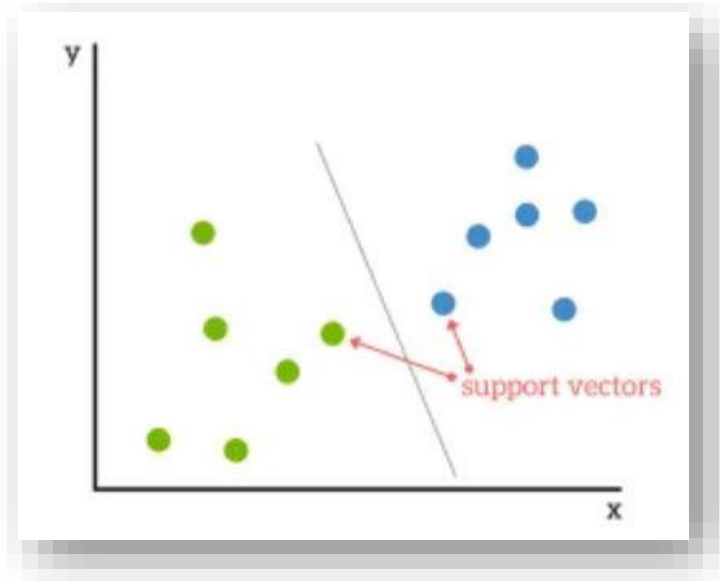
مثال آخر لاستخدامها في رسائل البريد الإلكتروني غير المرغوب فيها



4- خوارزمية المتجهات الداعمة Support Vector Machine

إحدى خوارزميات التعلم تحت إشراف (Supervised Learning) التي يمكن استخدامها في التصنيف (Classification) والانحدار (Regression)، وعادة تستخدم في التصنيف لفعاليتها وحصولها على دقة ممتازة في أغلب البيانات المستخدمة.

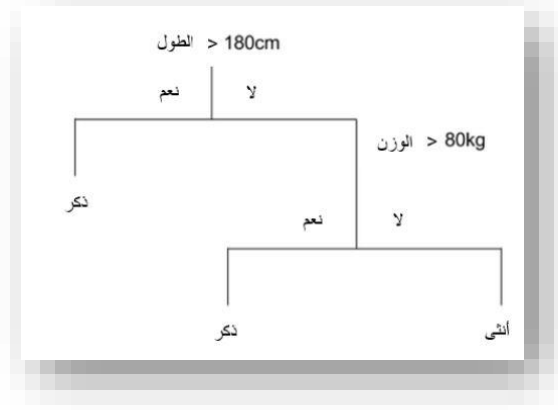
خوارزمية آلة المتجهات الداعمة SVM مبنية على فكرة إيجاد مستوى فائق (hyperplane) يقوم بتقسيم مجموعة البيانات إلى صنفين بأفضل طريقة كما هو موضح في الشكل أدناه.



عمل خوارزمية المتجهات الداعمة SVM

5- شجرة القرار Decision Tree

شجرة القرار هي شجرة ثنائية (binary tree) وهذا يعني أن لكل أب ولدين على الأكثر. حيث أن كل عقدة (node) في الشجرة تمثل متغيراً (variable) بينما أوراق الشجرة (leaf nodes) تمثل النتيجة (output) التي تستخدم للتنبؤ.




عمل أشجار القرار

6- الغابات العشوائية Random Forest

هي عبارة عن تحسين على أشجار القرار (Decision Tree) تسمى بالغابة العشوائية، وكما يوحي اسمها فهي تتكوّن من عدد كبير من أشجار القرار الفردية التي تعمل كمجموعة للحصول على تنبؤات أكثر دقة واستقراراً.

من نتائج تنبؤ هذه المجموعة يتم الحصول على أعلى نتيجة تصويت، وهي أفضل من نتيجة استخدام أفضل نموذج بمفرده.




عمل الغابات العشوائية

خوارزميات التعلم الاشرافي (التوقع Regression)

1- الانحدار الخطي Linear Regression

- يعتبر من أبسط الخوارزميات ضمن فئة التعلم تحت الإشراف (Supervised Learning) الذي يقوم بنمذجة مفهوم الانحدار .
- تستخدم في تفسير متغير Y عبر متغير آخر X أو مجموعة من المتغيرات (x_1, x_2, \dots, x_p) وفق دالة خطية .
- يسمى المتغير Y بالتابع .
- وتسمى المتغيرات X بالمتغيرات المستقلة أو المفردة بمعنى أنها تفسر تغيرات المتغير التابع Y .



الانحدار الخطي Linear Regression

ففي الشكل أعلاه يوضح علاقة خطية بسيطة بين متغيرين المتغير (X) والمتغير (Y) النقاط تمثل البيانات ، والخط الأحمر يمثل الانحدار الخطي الذي سيقوم بالتنبؤ لمقدار y حسب x ؛ أي نتيجة التنبؤ تكون قيماً مستمرة Continuous Values.

Gaussian Processes Regression- 2

العمليات الغوسية (GP) هي خوارزمية تعلم خاضعة للإشراف تستخدم لحل مشاكل الانحدار والتصنيف الاحتمالي . فتعتبر العمليات الغاوسية أداة قوية في صندوق أدوات التعلم الآلي حيث إنها تسمح بعمل تنبؤات حول بياناتنا من خلال دمج المعرفة السابقة، وأكثر مجالات التطبيق وضوحاً هو ملائمة وظيفة للبيانات، حيث يُسمى هذا بالانحدار ويستخدم في علم الروبوتات أو التنبؤ بالسلاسل الزمنية، لكن العمليات الغاوسية لا تقتصر على الانحدار بل يمكن أيضاً توسيعها لتشمل مهام التصنيف والتكامل.

ما هي عمليات غاوسين Gaussian Process ؟

عمليات غاوسين (Gaussian Process) هي طريقة جديدة للتعلم الآلي تعتمد على نظرية بايز ونظرية التعلم الإحصائي حيث يوفر إطاراً مرناً للانحدار الاحتمالي ويستخدم على نطاق واسع لحل مشكلات الانحدار عالية الأبعاد أو العينات الصغيرة أو غير الخطية، يحدد (GP) التوزيع على الوظائف حيث أنّ (GPs) هي امتداد لنموذج (Gaussian) متعدد المتغيرات إلى المتجه اللانهائي للمتغيرات ذات القيمة الحقيقية حيث يتم تحديد (GP) تماماً بواسطة دالة متوسطة ودالة تباين.

خصائص عمليات غاوسين: Gaussian Process –

1. التطبيع. (Normalization)
2. التهميش. (Marginalization)
3. التجميع. (Summation)
4. التكييف. (Conditioning)

تُستخدم العمليات الغاوسية عادةً لتوصيف مكون الضوضاء في أنظمة الاتصالات الرقمية، نظراً لأنها ناتجة بشكل أساسي عن تقلبات الضوضاء الحرارية، تم وصفها على أنها تقنية تقدير غير خطية في عام 1978 م وتم نسيانها بسرعة بسبب تعقيدها الحسابي، أما في منتصف التسعينيات أعيد اكتشافها بشكل مستقل منذ ذلك الحين ثبت أنها تناسب العديد من التطبيقات المختلفة. أما في الوقت الحاضر لم يعد تعقيدها الحسابي مشكلة مقيدة،

قدمت عمليات (Gaussian) للتعلم الآلي كأداة غير خطية جديدة لتصميم مستقبلات الاتصالات الرقمية، كما يمكن تطبيق عمليات (Gaussian) على مشاكل الانحدار والتصنيف لضبط مستقبلات الاتصالات الرقمية بتسلسلات تدريب قصيرة، حيث يتم مقارنة عمليات غاوسين للانحدار (GPR) وعمليات غاوسين للتصنيف (GPC) بأحدث المستقبلات الخطية وغير الخطية لإظهار قوتها في حل هذه المشاكل.

عمليات غاوس للانحدار: Gaussian Processes for Regression

تم تطوير أداة بايزية جديدة للتعلم الآلي تعتمد على العمليات الغاوسية (GPs) لتقدير الانحدار غير الخطي، حيث تفترض عمليات غاوس للانحدار (GPR) على أنّ (GP) يتحكم في مجموعة الانحدارات المحتملة، وبالتالي يتم إعطاء التوزيع المشترك

لبيانات التدريب والاختبار بواسطة دالة كثافة (multidimensional Gaussian) ويتم تقدير التوزيع المتوقع لكل نقطة اختبار عن طريق التكيف على بيانات التدريب، تقدم (GPR) من وجهة نظر الانحدار الخطي المعمم بايزي، وعلى الرغم من أنه يتم فقد من هذا الافتتاح تفسير (GPs) ولا يمكن العمل إلا مع نماذج الاحتمالية الغاوسية، إلا إنها طريقة أبسط لفهم (GPR).

عمليات غاوسية للتصنيف: Gaussian process for classification

عملية غاوسية للتصنيف أصعب قليلاً من نظير الانحدار، لأنه لا يتم الاعتماد على دالة الاحتمال الغاوسية للتنبؤ بتسميات كل فئة ولأن النتائج تأتي من مجموعة منفصلة، وبالتالي للتنبؤ بالتسميات نحتاج إلى اللجوء إلى التكامل العددي أو التقريب.

نواة عملية غاوسين: Gaussian process kernels

دالة النواة: (Kernel function) تصف النواة أو "دالة التغير" التغيرات في المتغيرات العشوائية لعملية غاوسية جنباً إلى جنب مع الوظيفة المتوسطة حيث تحدد النواة تماماً العملية الغاوسية.

نظرية الحد المركزي عند: Gaussian

نظرية الحدود المركزية: (Central Limit Theorem) هي نتيجة مهمة وركيزة في مجالات الإحصاء والاحتمالات، وتنص النظرية على أنه كلما زاد حجم العينة فإن توزيع المتوسط عبر عينات متعددة سيقارب التوزيع الغوسي.

آلية أخذ العينات في نظرية الحد المركزي عند: Gaussian

تُعد نظرية الحد المركزي مثيرة للإعجاب، خاصةً وأن هذا سيحدث بغض النظر عن شكل التوزيع الذي نستمد منه العينات حيث إنه يوضح أن توزيع الأخطاء من تقدير المجموعة يعني أنه يتناسب مع التوزيع الذي يعرفه مجال الإحصاء كثيراً.

سيكون تقدير التوزيع الغاوسية أكثر دقة مع زيادة حجم العينات المأخوذة من المجموعة، وهذا يعني أنه إذا استخدمنا معرفتنا بالتوزيع الغاوسية بشكل عام للبدء في إجراء استنتاجات حول وسائل العينات المأخوذة من المجموعات، فإن هذه الاستنتاجات ستصبح أكثر فائدة مع زيادة حجم العينة.

أحد التداعيات المثيرة للاهتمام لنظرية الحد المركزي هو أنه يمكن استخدامها لتوليد أرقام عشوائية غاوسية، كما يمكن إنشاء أعداد صحيحة عشوائية بشكل منتظم ومجموعات مجموع منها معاً حيث ستكون نتائج المجاميع غاوسية، وأن المتوسط هو مجرد المجموع الطبيعي للعينة وتُعد هذه الطريقة بإتقاناً طريقة أبسطاً لتوليد متغيرات جاوس العشوائية مقارنة بالطرق الأخرى مثل طريقة (Box – Muller)، ولكنها تطبيق واضح وذكي للنظرية.

تقترح عمليات (Gaussian) كجهاز استقبال غير خطي جديد لأنظمة الاتصالات الرقمية، كما يمكن استخدام إطار عمل (GPs) لحل مشاكل التصنيف (GPC) والانحدار (GPR)، وكذلك الحد الأدنى لمتوسط حل الخطأ التربيعي وهو توقع الرمز المرسل في ضوء المعلومات الموجودة في المستقبل، وهي وظيفة غير خطية للرموز المستقبلية للمدخلات المنفصلة، كما يمكن تقديم (GPR) كمقدر (MMSE) غير خطي وبالتالي قادر على تحقيق الأداء الأمثل من وجهة نظر (MMSE).

ويمكن النظر إلى تصميم مستقبلات الاتصالات الرقمية على أنه مشكلة اكتشاف، تناسب (GPC) بشكل خاص لأنها تعين الاحتمالات اللاحقة لكل رمز مرسل، وعمليات (Gaussian) هي أدوات التعلم الآلي (Bayesian) التي تصوغ دالة الاحتمال لمعلماتها الفائقة والتي يمكن بعد ذلك ضبطها على النحو الأمثل.

وبالنسبة لمجموعة معينة من نقاط التدريب من المحتمل أن يكون هناك عدد لا نهائي من الوظائف التي تناسب البيانات حيث تقدم عمليات (Gaussian) حلاً أنيقاً لهذه المشكلة عن طريق تعيين احتمال لكل من هذه الوظائف ثم يمثل متوسط توزيع الاحتمالات هذا التوصيف الأكثر احتمالية للبيانات، علاوة على ذلك يتيح لنا استخدام نهج احتمالي لدمج ثقة التنبؤ في نتيجة الانحدار

Support Vector Regression - 3

خوارزمية انحدار المتجه الداعم (SVR) هي خوارزمية تعلم آلي تُستخدم لتحليل الانحدار ، والتي تتضمن التنبؤ بالقيم العددية المستمرة. أيضا هي تندرج تحت خوارزمية آلة المتجهات الدعمة (SVM) ، الخوارزمية المعروفة الاستخدام لمهام التصنيف و التنبؤ.

في خوارزمية انحدار المتجه الداعم ، الهدف هو ملاءمة خط الانحدار الذي يفصل البيانات على أفضل وجه إلى فئتين ، حيث تمثل إحدى الفئات المتغير المستهدف ، بينما تمثل الفئة الأخرى الأخطاء المتبقية. يمثل خط الانحدار هذا المستوى الفائق الذي يزيد الهامش بين المتغير الهدف والأخطاء المتبقية. يتم تعريف الهامش على أنه المسافة بين المستوى الفائق وأقرب نقاط البيانات ، والمعروفة باسم متجه الدعم. التعامل مع العلاقات غير الخطية بين المتغيرات المستقلة والتابعة ويمكنها أيضاً التعامل مع القيم المتطرفة بشكل فعال. هذا يجعل خوارزمية انحدار متجه الدعم مفيدة لمهام التنبؤ المختلفة ، مثل التنبؤ بأسعار الأسهم ، والتنبؤ بالطقس. باختصار ، تعتبر خوارزمية انحدار متجه الدعم خوارزمية تعلم آلي قوية ومرنة ، خاصةً عندما تحتوي البيانات على علاقة غير خطية أو قيم متطرفة.

كيف تعمل خوارزمية انحدار المتجه الداعم؟

تحافظ خوارزمية انحدار المتجه الداعم على جميع الخصائص المثيرة للاهتمام في خوارزمية آلة المتجهات الداعمة. بحيث يتم استخدام نفس المبادئ التي يتم استخدامها في خوارزمية آلة المتجهات الداعمة للتصنيف، مع بعض الاختلافات الطفيفة. استناداً إلى البيانات المدرجة، فإن هذه الطريقة تحاول إيجاد منحنى. ومع ذلك ، بدلاً من أن يكون المنحنى بمثابة حدود للقرار في مسألة التصنيف، في خوارزمية انحدار المتجه الداعم SVR ، يتم إيجاد تطابق بين بعض المتجهات والموضع على المنحنى. ومع ذلك ، فإن الفكرة الرئيسية هي تقليل نسبة الخطأ في النتائج، وتخصيص المستوى الفائق الذي يزيد من قيمة الهامش إلى أقصى حد ، مع مراعاة أن جزءاً من الخطأ مسموح به.

التشابه بين SVM وSVR

خوارزمية انحدار المتجه الداعم SVR تشارك خوارزمية المتجهات الدعمة SVM في إيجاد أقرب تطابق بين نقاط البيانات والدالة الفعلية التي تمثلها. بشكل تلقائي، عندما تزيد المسافة بين المتجهات الداعمة إلى المنحنى المتراجع ، فإننا نقرب من

المنحنى الفعلي (نظرًا لوجود بعض الأخطاء دائمًا في العينات الإحصائية). ويتربط على ذلك أيضًا أنه يمكننا التخلص من جميع المتجهات التي ليست متجهات داعمة، لسبب بسيط هو أنها من المحتمل أن تكون قيم إحصائية متطرفة.

النواة Kernal و خوارزمية انحدار المتجه الداعم SVR

يمكن تطبيق طريقة النواة في خوارزمية انحدار المتجه الداعم SVR أيضًا. وبالتالي، من الممكن معالجة انحدار أي دالة غير خطية، أو منحى باستخدام خوارزمية انحدار المتجه الداعم SVR. وبالمثل، يتم تعيين البيانات غير الخطية على مساحة تجعل البيانات خطية. في حالة خوارزمية انحدار المتجه الداعم SVR، لا يلزم أن تكون خطية من أجل فصل مجموعتين، بل لتمثيل خط مستقيم وبالتالي حساب مساهمة متجهات الدعم في مسألة التنبؤ.

أنواع خوارزمية انحدار المتجه الداعم SVR


هناك عدة أنواع من خوارزمية انحدار المتجه الداعم SVR بناءً على نوع النواة المستخدمة لنمذجة العلاقة بين المتغيرات، منها:

1. انحدار المتجه الداعم ذو النواة الخطية: يستخدم هذا النوع من خوارزمية انحدار المتجه الداعم نواة خطية لنمذجة العلاقة بين المتغيرات.
 2. انحدار المتجه الداعم ذو النواة متعدد الحدود: يستخدم هذا النوع من انحدار المتجه الداعم نواة متعددة الحدود لنمذجة العلاقة غير الخطية بين المتغيرات.
 3. انحدار المتجه الداعم ذو نواة دالة الأساس الشعاعي (RBF): يستخدم هذا النوع من انحدار المتجه الداعم نواة دالة الأساس الشعاعي لنمذجة العلاقة غير الخطية بين المتغيرات. دالة الأساس الشعاعي هي واحدة من أكثر النوى شيوعًا المستخدمة في انحدار المتجه الداعم.
 4. انحدار المتجه الداعم ذو نواة دالة سيجمويد: يستخدم هذا النوع من انحدار المتجه الداعم نواة دالة سيجمويد لنمذجة العلاقة غير الخطية بين المتغيرات.
 5. انحدار المتجه الداعم ذو نواة الشبكة العصبية: ANN يستخدم هذا النوع من انحدار المتجه الداعم الشبكات العصبية الاصطناعية لنمذجة العلاقة بين المتغيرات.
- لكل نواة من نوى انحدار المتجه الداعم نقاط قوة ونقاط ضعف ويعتمد اختيار النواة المناسبة على طبيعة البيانات والمشكلة التي يتم حلها.


في معظم نماذج الانحدار الخطي البسيط، يكون الهدف الرئيسي هو تقليل نسبة الخطأ. إذا أخذنا المربعات الصغرى الخطية OLS على سبيل المثال. إن دالة الهدف لـ OLS مع ميزة أو خاصية واحدة يمكن وصفها كالتالي:

$$MIN \sum_{i=1}^n (y_i - w_i x_i)^2$$

حيث y_i هو الهدف، و w هو معامل الوزن، و x_i هي الميزة أو الخاصية.




يمكننا انحدار المتجه الداعم المرنة لتحديد مقدار الخطأ المقبول في النموذج الذي نعمل عليه وسيجد خطأً مناسباً (أو سطحاً فائقاً بأبعاد أعلى) لملاءمة البيانات.



رسم توضيحي لانحدار المتجه الداعم SVR البسيط

يمكن تجربة طريقة انحدار المتجه الداعم SVR البسيط في مجموعة بيانات اسعار المباني في منطقة ما . يوضح المخطط أدناه نتائج نموذج انحدار المتجه الداعم SVR البسيط المدرب على بيانات أسعار الإسكان في المدينة. الخط الأحمر يمثل الخط الأكثر ملاءمة والخطوط السوداء تمثل هامش الخطأ ، ϵ ، الذي قمنا بتعيينه إلى 5 (5000 دولار).



توقع انحدار المتجه الداعم SVR لأسعار المباني في بوسطن مع قيمة ϵ تساوي 5

دالة الفقد مع متغيرات الركود


قد تدرك بسرعة أن هذه الخوارزمية لا تعمل مع جميع نقاط البيانات. حلت الخوارزمية دالة الهدف بأفضل طريقة ممكنة ولكن بعض النقاط لا تزال تقع خارج الهوامش. على هذا النحو ، نحتاج إلى حساب احتمال أخطاء أكبر من ϵ . يمكننا القيام بذلك مع متغيرات الركود. مفهوم متغيرات الركود بسيط: بالنسبة لأي قيمة تقع خارج ϵ ، يمكننا أن نشير إلى انحرافها عن الهامش كـ ξ . نحن نعلم أن هذه الانحرافات وجودها معقول ، ولكننا ما زلنا نرغب في تقليلها قدر الإمكان. وبالتالي ، يمكننا إضافة هذه الانحرافات إلى الدالة الموضوعية أو دالة الفقد.

دالة الفقد Minimize

$$\text{MIN } \frac{1}{2} \|\mathbf{w}\|^2 + C \sum_{i=1}^n |\xi_i|$$

الحدود Constraints


$$|y_i - w_i x_i| \leq \varepsilon + |\xi_i|$$



انحدار المتجه الداعم SVR مع متغيرات الركوند Slack

لدينا الآن مستوى فائق إضافي C ، يمكن ضبطه. كلما زادت قيمة المستوى C ، زادت احتمالية وجود النقاط خارج حدود ε أيضًا. مع اقتراب C من 0 ، يقترب الاحتمال من 0 وتنهز المعادلة إلى المعادلة المبسطة (على الرغم من أنها غير ممكنة في بعض الأحيان).


دعونا نضع قيمة $C = 1.0$ ونعيد تدريب النموذج أعلاه. تم رسم النتائج أدناه:



توقع انحدار المتجه الداعم SVR لأسعار المباني مع $\epsilon = 5$ ، $C = 1.0$

إيجاد أفضل قيمة لـ C


يبدو أن النموذج أعلاه قلل نسبة الخطأ نسبياً و أعطى نتائج أفضل من سابقه. يمكننا أن نخطو خطوة أخرى ونبحث على قيمة أخرى لـ C للحصول على حل أفضل. لنفترض أن مقياس التقييم سيكون % Within Epsilon. يقيس هذا التقييم عدد النقاط الإجمالية ضمن مجموعة الاختبار التي تقع ضمن هامش الخطأ. يمكننا أيضاً مراقبة كيفية اختلاف متوسط الخطأ المطلق (MAE) مع قيمة C أيضاً.



إيجاد قيمة C المثالية بناء على قيمة % within Epsilon و متوسط الخطأ المطلق (MAE)

كما نرى ، تقل نسبة الخطأ MAE بشكل عام مع زيادة قيمة C. ومع ذلك ، نرى الحد الأقصى يحدث في تقييم within Epsilon% ونظرًا لأن هدفنا الأصلي من هذا النموذج كان زيادة التنبؤ ضمن هامش الخطأ الذي حددناه (5000 دولار أمريكي) ، فإننا نريد إيجاد قيمة C التي تكون عندها قيمة % within Epsilon قصوى. وبالتالي قيمة C في هذه الحالة تساوي تقريبًا 6.13. بناءً على هذه القيمة نبني نموذجًا أخيرًا باستخدام العوامل الفائقة النهائية ، $\epsilon = 5$ ، $C = 6.13$.

يظهر الرسم البياني أعلاه أن هذا النموذج قد تحسن كثيرًا مقارنة بالنماذج السابقة ، كما هو متوقع.

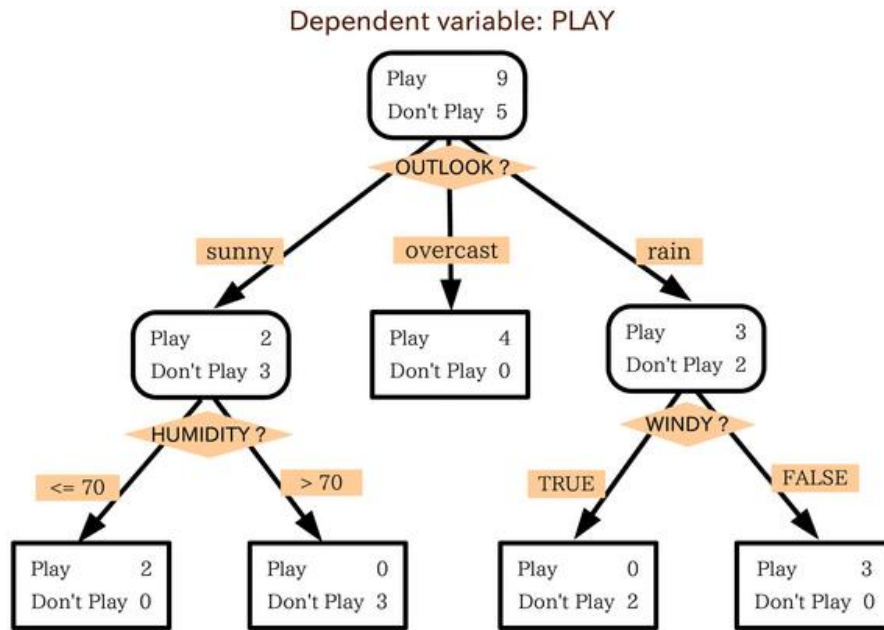


توقع انحدار المتجه الداعم SVR لأسعار المباني مع $\epsilon = 5$ ، $C = 6.13$

Ensemble Methods - 4

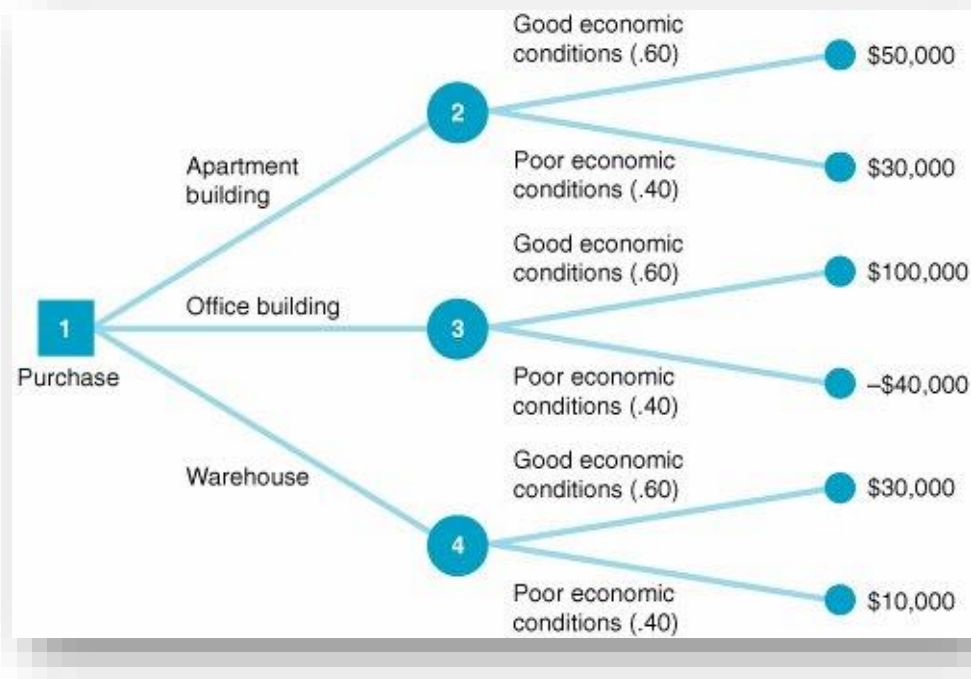
هي تقنية للتعلم الآلي تجمع بين عدة نماذج أساسية لإنتاج نموذج تنبؤي واحد مثالي. لفهم هذا التعريف بشكل أفضل، دعونا نعود خطوة إلى الهدف النهائي المتمثل في التعلم الآلي وبناء النماذج. سيكون هذا أكثر منطقيًا عندما أتعلم في أمثلة محددة ولماذا يتم استخدام أساليب Ensemble.

كبير لتوضيح التعريف والتطبيق العملي يمكن استخدام شجرة القرار لأساليب المجموعة (ومع ذلك من المهم ملاحظة أن أساليب المجموعة لا تتعلق فقط بشجرة القرار).



تحدد شجرة القرار القيمة التنبؤية بناءً على سلسلة من الأسئلة والشروط. على سبيل المثال، تحدد شجرة القرار البسيطة هذه ما إذا كان يجب على الفرد اللعب في الخارج أم لا. تأخذ الشجرة عدة عوامل مناخية بعين الاعتبار، ونظرًا لكل عامل إما أنها تتخذ قرارًا أو تطرح سؤالاً آخر. في هذا المثال، في كل مرة يكون الجو ملبدًا بالغيوم، سنلعب في الخارج. لكن إذا نزل المطر يجب أن نسأل هل الجو عاصف أم لا؟ إذا كانت الرياح عاصفة، فلن نلعب. ولكن في حالة عدم وجود ربح، قم بربط أربطة الحذاء بإحكام لأننا سنذهب للعب بالخارج.

يمكن لأشجار القرار أيضاً حل المشكلات الكمية بنفس التنسيق. في الشجرة الموجودة على اليسار، نريد أن نعرف ما إذا كنا نستثمر في عقار تجاري أم لا. هل هو مبنى مكاتب؟ مستودع أو مخزن المنزل؟ مبنى سكني؟ ظروف اقتصادية جيدة؟ الظروف الاقتصادية السيئة؟ كم سيعود عائد الاستثمار؟ يتم الإجابة على هذه الأسئلة وحلها باستخدام شجرة القرار هذه.

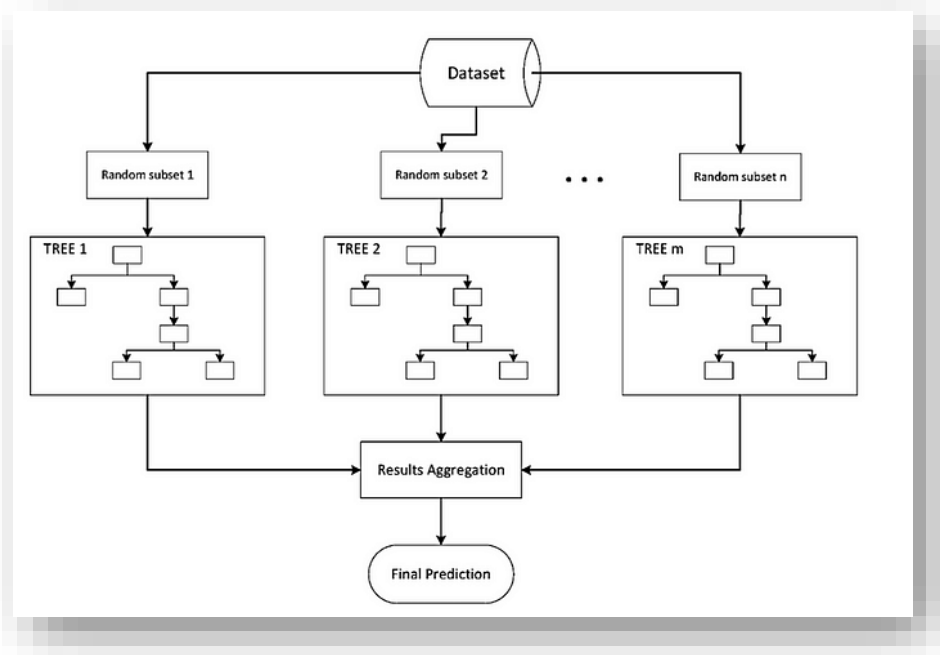


عند اتخاذ شجرة القرار، هناك عدة عوامل يجب أن نأخذها في الاعتبار: ما هي الميزات التي نتخذ قراراتنا بشأنها؟ ما هو الحد الأدنى لتصنيف كل سؤال إلى إجابة بنعم أو لا؟ في شجرة القرار الأولى، ماذا لو أردنا أن نسأل أنفسنا إذا كان لدينا أصدقاء للعب معهم أم لا. إذا كان لدينا أصدقاء، سوف نلعب في كل مرة. إذا لم يكن الأمر كذلك، فقد نستمر في طرح الأسئلة على أنفسنا حول الطقس. من خلال إضافة سؤال إضافي، نأمل في تحديد فئتي "نعم" و"لا" بشكل أكبر.

هذا ما يجعل أساليب المجموعة مفيدة! بدلاً من الاعتماد فقط على شجرة قرار واحدة والأمل في اتخاذ القرار الصحيح في كل قسم، تسمح لنا الأساليب المجمعّة بأخذ عينة من أشجار القرار في الاعتبار، وحساب الميزات التي يجب استخدامها أو الأسئلة التي يجب طرحها في كل قسم، وإجراء تقييم نهائي متنبئ يعتمد على النتائج المجمعّة لأشجار القرار التي تم أخذ عينات منها.


أنواع طرق المجموعة

1. *BAGging*، أو *Bootstrap AGG regating* حصلت *BAGging* على اسمها لأنها تجمع بين *Bootstrapping* و *Aggregation* لتشكيل نموذج جماعي واحد. بالنظر إلى عينة من البيانات، يتم سحب عينات فرعية متعددة تم تمهيدها. يتم تشكيل شجرة القرار على كل من العينات الفرعية التي تم تمهيدها. بعد تشكيل كل شجرة قرار فرعية، يتم استخدام خوارزمية للتجميع فوق أشجار القرار لتشكيل المنتبئ الأكثر كفاءة كما موضح ادناه:



بالنظر إلى مجموعة البيانات، يتم سحب العينات الفرعية التي تم تمهيدها. يتم تشكيل شجرة القرار على كل عينة تمهيدية. ويتم تجميع نتائج كل شجرة للحصول على أقوى وأدق أداة تنبؤ.

2- نماذج الغابات العشوائية. يمكن اعتبار نماذج الغابات العشوائية بمثابة *BAGging*، مع تعديل طفيف. عند تحديد مكان التقسيم وكيفية اتخاذ القرارات، تتمتع أشجار القرار *BAGged* بالتخلص الكامل من الميزات للاختيار من بينها. لذلك، على الرغم من أن العينات التي تم تمهيدها قد تكون مختلفة قليلاً، إلا أن البيانات ستنتقسم إلى حد كبير عند نفس الميزات في كل نموذج. على العكس من ذلك، تحدد نماذج *Random Forest* مكان التقسيم بناءً على مجموعة عشوائية من الميزات. بدلاً من التقسيم إلى ميزات متشابهة في كل عقدة، تنفذ نماذج *Random Forest* مستوى من التمايز لأن كل شجرة ستنتقسم بناءً على ميزات مختلفة. يوفر هذا المستوى من التمايز مجموعة أكبر للتجميع، مما يؤدي إلى إنتاج تنبؤ أكثر دقة.



على غرار BAGging ، يتم سحب العينات الفرعية التمهيدية من مجموعة بيانات أكبر. يتم تشكيل شجرة القرار على كل عينة فرعية. ومع ذلك، يتم تقسيم شجرة القرار على ميزات مختلفة (في هذا المخطط، يتم تمثيل الميزات بالأشكال).

خوارزميات التعلم غير الاشرافي (Clustering)

K-Means Clustering -1

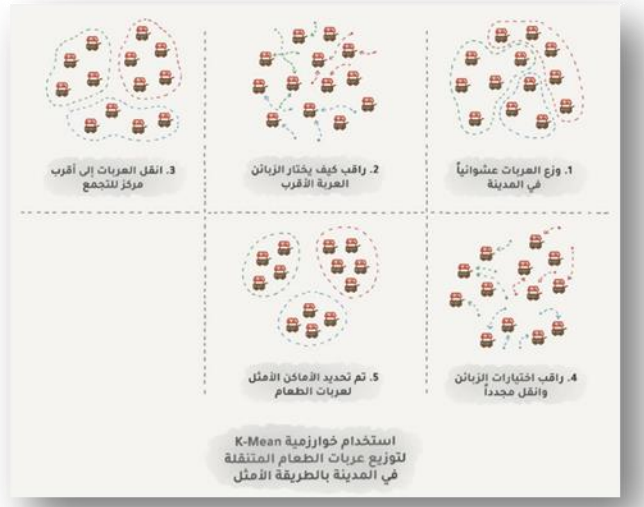
خوارزميات Clustering مثلها مثل خوارزميات التصنيف لكن دون أصناف معرفة مسبقاً، فتحاول الخوارزمية العثور على الكائنات المتشابهة من خلال بعض الميزات ثم دمجها في مجموعة واحدة. تصبح كل الكائنات التي لديها ميزات متشابهة في صنف واحد. وباستخدام بعض الخوارزميات الأخرى يمكننا تحديد عدد الفصول التي نحتاج إليها بشكل دقيق.

فكرة تحديد المواقع على الخرائط برمز محدد مثال جيداً على Clustering ، فعندما نبحث عن جميع المدارس الموجودة حولنا ، تقوم خوارزمية Clustering بتجميع هذه المدارس على شكل نقاط تحتوي على عدد هذه المدارس.

تستخدم تطبيقات الصور في هواتفنا خوارزميات Clustering أكثر تعقيداً، تبحث عن الوجوه في الصور المحفوظة لدينا ثم تقوم بإنشاء ألبوم لأصدقائنا كلاً على حدى. تحاول هذه الخوارزميات العثور على ميزات مشتركة في الوجوه ثم تقوم بتجميع كافة الصور التي تحتوي هذه الوجوه تحت ألبوم واحد وهكذا تكون قد كونت عدة عناقيد كل منها يبدأ بالألبوم ويحتوي على مجموعة من الصور. لاحظ أن هذه الخوارزميات لا تعرف عدد الاصدقاء لدينا ولا كيف يبدو لكنها قادرة على تجميعهم بالنظر إلى ميزات وجوههم فقط.

عملية تجميع البيكسلات في الصور (ضغط الصور) من المشاكل الشائعة التي تعالجها خوارزميات Clustering. يمكننا ضبط لوحة الألوان على 32 لوناً عند حفظ صورة بصيغة PNG على سبيل المثال، هذا يعني أن خوارزمية Clustering ستجد جميع


وحدات البكسل الحمراء، وذلك بحساب متوسط اللون الأحمر وإعادة ضبطه للون الذي تم تحديده من بين الـ 32 لون، ما يعني ان الصورة الناتجة ستحتوي ألواناً أقل بالتالي حجم الصورة يكون أصغر.



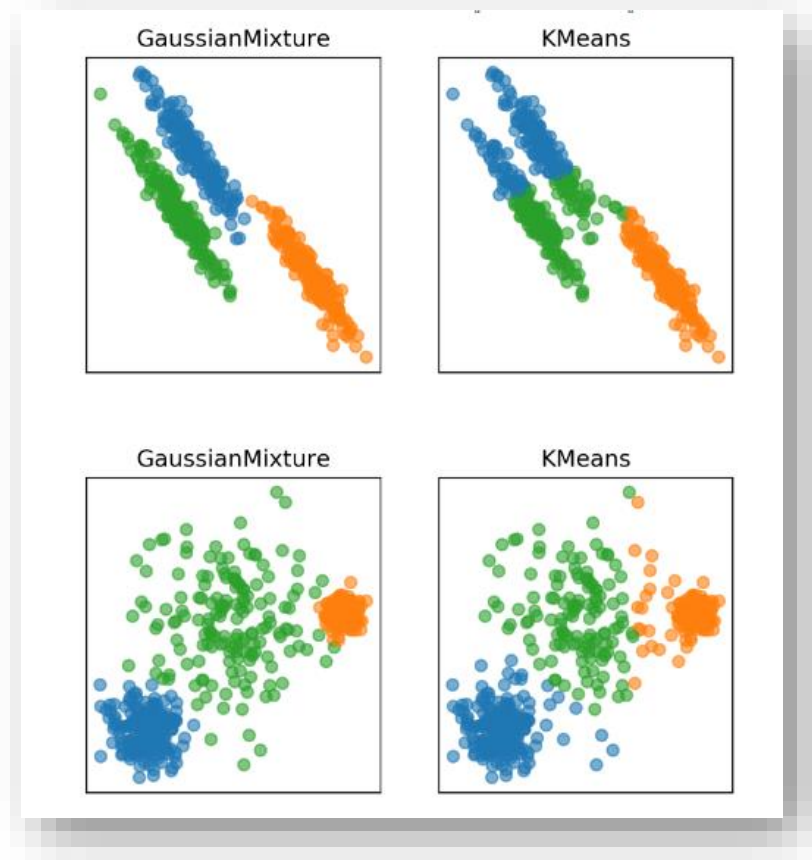
Gaussian Mixtures(GMM) - 2

خوارزمية تجميع، مشابهة لـ K-mean ولكن تأخذ بعين الاعتبار التباين في القيم . حيث تستخدم الـ Gaussian وهي طريقة لرسم البيانات وفهم الخوارزمية لكيفية تشكيلها.

- المتوسط **Mean** : وهو دائماً يكون في وسط الـ Cluster
- التباين: **Variance** ويشكل طريقة توسع البيانات في الـ Cluster ففي الشكل التالي القيم شكلت 4 مجموعات وكما يظهر لنا طريقة توسعها بسبب عمل الخوارزمية على المتوسط والتباين لتشكيل الـ Clusters، على عكس ما كانت عليه خوارزمية-K mean التي تكون افضل على البيانات ذات الشكل الدائري .



وللتوضيح بشكل أدق ففي الشكل التالي الفرق بين خوارزمية Gaussian Mixtures , K Means في طريقة تجميع الفئات



طريقة عمل خوارزمية GMM :-

- اختيار K كعدد لل Clusters وأختيار نقاط بداية عشوائية.
- نحدد لكل نقطة في البيانات Cluster خاص بها.
- نحسب المسافة والتباين بين كل نقطة والنقطة المركزية، ثم نقوم بتغير موقع النقطة المركزية، ثم إعادة الحساب للمتوسط والتباين.
- اذا توقف التغير في المتوسط يتم إختيار المنطقة كنقطة مركزية جديدة.

طريقة تحليل Clusters

Feature Selecting: اختيار المتغيرات او الخصائص المناسبة وتوجد طرق لإختيار الأفضل.

Clustering Algorithm: اختيار الخوارزمية المناسبة في التجميع وإعادة ضبطها حتى نصل لنتائج مرضية.

Clustering Validation: التحقق وعرض النتائج وتقييمها.

Cluster Validation

في التعليم الموجه كانت لدينا خيارات تقييم للمودل ك Accuracy و Precision، في التعلم غير الموجه توجد ثلاث خيارات لتقييم ال Cluster وهي :

- **External Index**: يتم فيه مقارنة النتائج في ال Cluster مع النتائج الصحيحة (Labels) المعروفة مسبقاً.
- **Internal Index**: يتحقق من النتائج لـ Cluster بدون الإعتماد على النتائج الصحيحة (ان لم تكن موجودة مثلاً).
- **Silhouette Coefficient**: طريقة لحساب اداء ال Cluster اذا لم تكن هناك نتائج (Labels) عن طريق المعادلة التالية:

$$S_i = \frac{b_i - a_i}{\text{Max}(b_i - a_i)}$$

a = معدل المسافة من نقطة إلى النقاط الأخرى في نفس ال Cluster
b = معدل المسافة من نقطة إلى النقاط الأخرى في أقرب Cluster والتي تحتوي على نقطتنا الحالية.
نكرر هذه العملية على كل نقطة لدينا، ثم نجمع النتائج ونأخذ المعدل. وهو بالغالب رقم من -1 إلى 1 .
ملاحظة: لا تستخدم هذه العملية مع Density-Based Clustering لأنها تعطي نتائج خاطئة.

- **Relative Index** : تقارن بين اثنين من ال Clusters.

3- Hierarchical Clustering التجميع الهرمي

تعمل طريقة التجميع الهرمي من خلال تجميع البيانات في شجرة من المجموعات. يبدأ التجميع الهرمي بمعاملة كل نقطة بيانات كمجموعة منفصلة. ثم يقوم بشكل متكرر بتنفيذ الخطوات التالية:

- تحديد المجموعتين اللتين يمكن أن تكونا الأقرب لبعضهما.
- دمج الحد الأقصى للمجموعتين القابلتين للمقارنة.
- في المجموعات الهرمية، الهدف هو إنتاج سلسلة هرمية من المجموعات المتداخلة. (رسم تخطيطي يسمى Dendrogram) هو رسم تخطيطي يشبه الشجرة يقوم بإحصاء تسلسل عمليات الدمج أو الانقسامات يمثل هذا التسلسل الهرمي بيانياً وهو عبارة عن شجرة مقلوبة

تصف الترتيب الذي يتم به دمج العوامل (عرض من أسفل إلى أعلى) أو يتم تقسيم المجموعات لأعلى (عرض من أعلى إلى أسفل).

ما هو التجميع الهرمي؟

التجميع الهرمي هو طريقة لتحليل المجموعات في استخراج البيانات والتي تنشئ تمثيلاً هرمياً للمجموعات في مجموعة البيانات. تبدأ الطريقة بمعاملة كل نقطة بيانات كمجموعة منفصلة ثم تجمع بشكل متكرر أقرب المجموعات حتى يتم الوصول إلى معيار التوقف. نتيجة التجمع الهرمي هي بنية تشبه الشجرة، تسمى مخطط الأشجار، والتي توضح العلاقات الهرمية بين المجموعات.

يتمتع التجميع الهرمي بالعديد من المزايا مقارنة بطرق التجميع الأخرى:

- القدرة على التعامل مع التجمعات غير المحدبة والتجمعات ذات الأحجام والكثافات المختلفة.
- القدرة على التعامل مع البيانات المفقودة والبيانات المزعجة.
- القدرة على الكشف عن البنية الهرمية للبيانات، والتي يمكن أن تكون مفيدة لفهم العلاقات بين المجموعات.

عيوب التجميع الهرمي

- ضرورة وجود معيار لوقف عملية التجميع وتحديد العدد النهائي للمجموعات.
 - يمكن أن تكون التكلفة الحسابية ومتطلبات الذاكرة لهذه الطريقة مرتفعة، خاصة بالنسبة لمجموعات البيانات الكبيرة.
 - يمكن أن تكون النتائج حساسة للشروط الأولية، ومعايير الربط، ومقياس المسافة المستخدم.
- باختصار، التجميع الهرمي هو أسلوب لاستخراج البيانات يجمع نقاط بيانات مماثلة في مجموعات عن طريق إنشاء هيكل هرمي للمجموعات.
- يمكن لهذه الطريقة التعامل مع أنواع مختلفة من البيانات وكشف العلاقات بين المجموعات. ومع ذلك، يمكن أن يكون لها تكلفة حسابية عالية ويمكن أن تكون النتائج حساسة لبعض الشروط.

أنواع المجموعات الهرمية : هناك نوعان من المجموعات الهرمية:

- التجمعات التكتلية
- التجمعات الانقسامية

أولاً: التجمعات التكتلية:

حيث يتم اعتبار كل نقطة بيانات بمثابة مجموعة فردية وفي كل خطوة، يتم دمج أقرب أزواج المجموعة. (إنها طريقة من أسفل إلى أعلى). في البداية، تعتبر كل مجموعة بيانات كياناً فردياً أو مجموعة. في كل تكرار، تندمج المجموعات مع مجموعات مختلفة حتى يتم تشكيل مجموعة واحدة.

تقوم خوارزمية التجميع الهرمي التكتل على النحو التالي:

حساب تشابه مجموعة واحدة مع جميع المجموعات الأخرى (حساب مصفوفة القرب)

اعتبار كل نقطة بيانات بمثابة مجموعة فردية

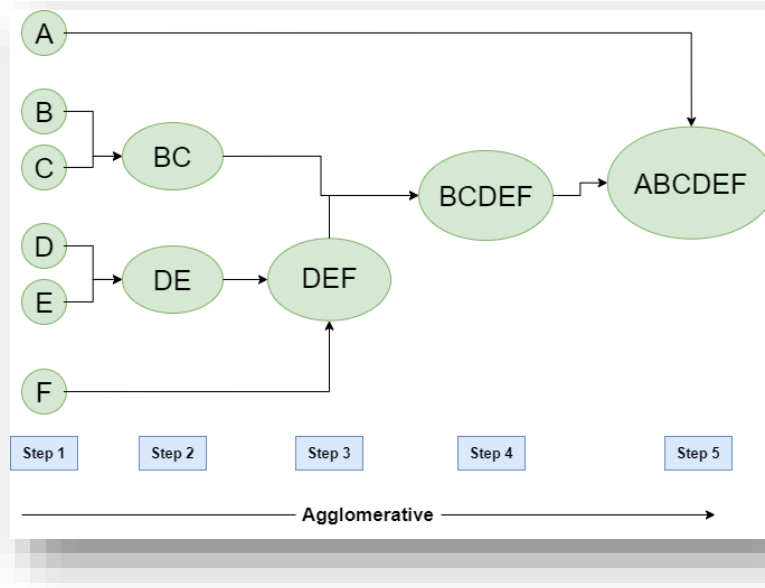
دمج المجموعات المتشابهة إلى حد كبير أو القريبة من بعضها البعض.

إعادة حساب مصفوفة القرب لكل مجموعة

تكرار الخطوتين 3 و 4 حتى تبقى مجموعة واحدة فقط.

مثال يوضح طريقة عمل الخوارزمية

نفترض أن لدينا ست نقاط بيانات A و B و C و D و E و F.



1- افترض أن كل أبجدية بمثابة مجموعة واحدة وبحساب مسافة مجموعة واحدة من جميع المجموعات الأخرى.
 2- يتم دمج المجموعات المماثلة معاً لتكوين مجموعة واحدة. لنفترض أن المجموعة (B) والمجموعة (C) متشابهتان جداً مع بعضهما البعض، لذلك قمنا بدمجهما في الخطوة الثانية بشكل مشابه للمجموعة (D) و (E) وفي النهاية، حصلنا على المجموعات [(A), (BC), (DE), (F)]

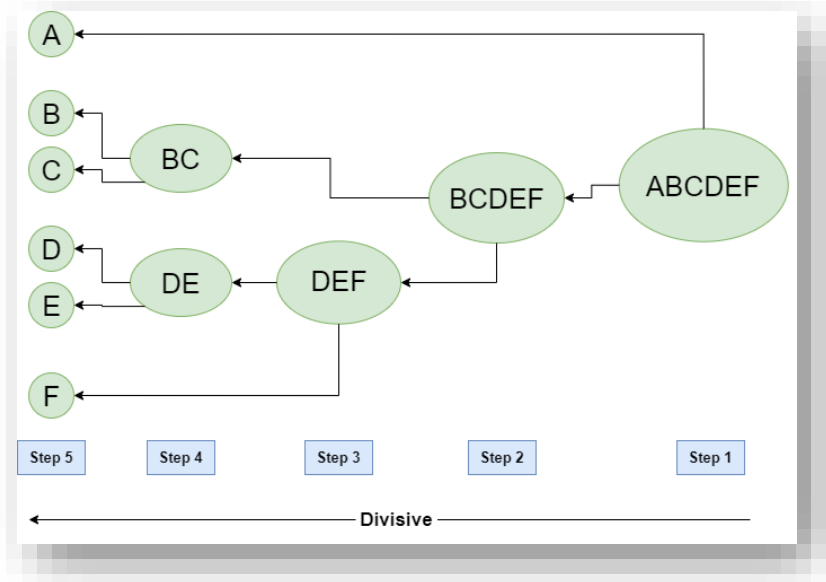
3- إعادة حساب المجموعات وفقاً للخوارزمية وندمج أقرب مجموعتين ((DE), (F)) معاً لتكوين مجموعات جديدة مثل [(A), (BC), (DEF)]

4- تكرر نفس العملية؛ المجموعتان BC و DEF قابلتان للمقارنة ويتم دمجها معاً لتكوين مجموعة جديدة. يتبقى لدينا الآن المجموعات [(A), (BCDEF)]

5- أخيراً، يتم دمج المجموعتين المتبقيتين معاً لتكوين مجموعة واحدة [(ABCDEF)].

ثانياً: المجموعات الهرمية المقسمة:

يمكننا القول أن التجميع الهرمي المقسم هو بالضبط عكس التجميع الهرمي التكتلي. في التجميع الهرمي المقسم، نأخذ في الاعتبار جميع نقاط البيانات كمجموعة واحدة وفي كل تكرار، نقوم بفصل نقاط البيانات عن المجموعات غير القابلة للمقارنة. في النهاية، يتبقى لدينا مجموعات N.



4- Spectral Clustering التجميع الطيفي

5- Boosting التعزيز:

التعزيز عبارة عن إستراتيجية تعلم آلي خاضعة للإشراف تجمع بين تنبؤات النماذج الضعيفة المتعددة (النماذج الأساسية) لإنشاء نموذج مجمع قوي. يركز التعزيز، على عكس أساليب المجموعة الكلاسيكية مثل التعبئة أو المتوسط، على تدريب النماذج الأساسية بشكل متتابع بطريقة تؤكد على العينات التي تم تصنيفها بشكل خاطئ من التكرارات السابقة. الهدف هو تحديد أولويات العينات التي تم تصنيفها بشكل غير صحيح في التكرارات السابقة، مما يسمح للنموذج بالتعلم من أخطائه وتحسين أدائه بشكل متكرر.

كيف يعمل التعزيز؟

فيما يلي خطوات خوارزمية التعزيز:

تهيئة الأوزان Initialise weights: في بداية العملية، يتم إعطاء كل مثال تدريبي وزناً متساوياً.

تدريب متعلم ضعيف Train a weak learner: يتم استخدام بيانات التدريب الموزونة لتدريب متعلم ضعيف. المتعلم الضعيف هو نموذج بسيط يتفوق على التخمين العشوائي بشكل هامشي فقط. على سبيل المثال، يمكن استخدام شجرة القرار ذات المستويات القليلة كمتعلم ضعيف.

حساب الخطأ Error calculation: يتم حساب خطأ المتعلم الضعيف في بيانات التدريب. ويشكل المجموع المرجح للحالات المصنفة خطأً.

تحديث الأوزان Update weights: يتم تحديث الأوزان حسب معدل الخطأ في الأمثلة التدريبية. يتم إعطاء الأمثلة المصنفة بشكل خاطئ أوزان أعلى، في حين يتم إعطاء الأمثلة المصنفة بشكل صحيح أوزان أقل.

تكرار العملية: يتم تكرار الخطوات من 2 إلى 4 عدة مرات. يتم تدريب المتعلم الضعيف الجديد على الأوزان المحدثة للأمثلة التدريبية في كل دورة.

دمج المتعلمين الضعفاء Combine weak learners: يتكون النموذج النهائي من جميع المتعلمين الضعفاء الذين تم تدريبهم في الخطوات السابقة. يتم ترجيح دقة كل متعلم ضعيف، ويستند التنبؤ النهائي إلى المجموع المرجح للمتعلمين الضعفاء.

التنبؤ: يتم استخدام النموذج النهائي للتنبؤ بتسميات فئات المثيلات الجديدة.

تم تصميم أسلوب التعزيز لإنتاج متعلم قوي ودقيق في بيانات التدريب ويمكنه التعميم بفعالية على البيانات الجديدة.

يمكن للخوارزمية إنتاج نموذج أكثر دقة من أي نموذج من المتعلمين الضعفاء من خلال دمج العديد من المتعلمين الضعفاء.
طرق مختلفة للتعزيز

هناك أنواع مختلفة من الخوارزميات المعززة التي يمكن استخدامها في التعلم الآلي. فيما يلي أشهرها:

AdaBoost (التعزيز التكيفي): هي واحدة من خوارزميات التعزيز الأكثر استخدامًا على نطاق واسع. فهو يعطي أوزانًا لكل نقطة بيانات في مجموعة التدريب بناءً على دقة النماذج السابقة، ثم يقوم بتدريب نموذج جديد باستخدام الأوزان المحدثة. يعد AdaBoost مفيدًا جدًا لمهام التصنيف.

Gradient Boosting (تعزيز التدرج): يعمل تعزيز التدرج عن طريق ملاءمة النماذج الجديدة مع الأخطاء المتبقية في النماذج السابقة. إنه يقلل من دالة الخسارة باستخدام النسب المتدرجة ويمكن تطبيقه على كل من مشاكل الانحدار والتصنيف. تتضمن تطبيقات تعزيز التدرج الشائعة XGBoost و LightGBM.

Stochastic Gradient Boosting (تعزيز التدرج العشوائي): على غرار تعزيز التدرج، يناسب تعزيز التدرج العشوائي كل نموذج جديد مع مجموعات فرعية عشوائية من بيانات التدريب ومجموعات فرعية عشوائية من الميزات. يساعد هذا على تجنب التجهيز الزائد وقد يؤدي إلى تحسين الأداء.

LPBoost (تعزيز البرمجة الخطية (Linear Programming Boosting)): عبارة عن خوارزمية معززة تقلل من وظيفة الخسارة الأسية باستخدام البرمجة الخطية. وتكون قادرة على التعامل مع مجموعة واسعة من وظائف الخسارة ويمكن تطبيقها على كل من قضايا الانحدار والتصنيف.

TotalBoost (التعزيز الإجمالي): عبارة عن طريقة تعزيز AdaBoost و LPBoost. وهو يعمل عن طريق تقليل مزيج من خسائر البرمجة الأسية والخطية، ويمكنه زيادة الدقة لأنواع معينة من المشاكل.

سيتم تحديد الخوارزمية المختارة من خلال التحدي المحدد المطروح بالإضافة إلى ميزات مجموعة البيانات.

هنا مقارنة بين الأنواع المختلفة من خوارزميات التعزيز، مع الأمثلة ونقاط قوتها وهي موضحة بالجدول التالي :

Algorithm	Description	Example	Strengths
AdaBoost	Assigns weights to data points and trains new models on updated weights	Classification problems with large number of features or complex decision boundaries	Works well with weak learners, less prone to overfitting, fast to train
Gradient Boosting	Fits new models to the residual errors of previous models	Regression and classification problems with complex interactions between features	More flexible than AdaBoost, can handle non-linear relationships between features, good for handling high-dimensional data
Stochastic Gradient Boosting	Uses random subsets of training data and features for each new model	Large datasets with many features and noisy data	Robust to overfitting, faster than traditional gradient boosting, good for handling high-dimensional data
LPBoost	Uses linear programming to minimize exponential loss function	Regression and classification problems with sparse data or high-dimensional feature spaces	Can handle a wide range of loss functions, works well with sparse data, can handle large number of features
TotalBoost	Combines AdaBoost and LPBoost to minimize combination of exponential loss and linear programming loss	Classification and regression problems with complex decision boundaries and sparse data	Can improve accuracy over AdaBoost and LPBoost, works well with sparse data, can handle high-dimensional feature spaces

يوفر التعزيز فوائد متعددة، منها :

الأداء المحسّن: نظرًا لأن التعزيز يجمع بين تنبؤات أي نماذج أساسية، فإنه يقلل بشكل فعال من التحيز والتباين، مما يؤدي إلى تنبؤات أكثر دقة وقوة.

القدرة على التعامل مع البيانات المعقدة: يمكن أن يتعامل التعزيز مع أنماط البيانات المعقدة، بما في ذلك الارتباطات والتفاعلات غير الخطية، مما يجعله مناسبًا لمجموعة واسعة من تطبيقات التعلم الآلي مثل التصنيف والانحدار والتصنيف.

المتانة في مواجهة الضوضاء: عند مقارنتها بتقنيات التعلم الآلي الأخرى، يكون التعزيز أقل عرضة للضوضاء في بيانات التدريب لأنه يركز على العينات المصنفة بشكل خاطئ ويعطي أوزانًا أكبر لها، مما يقلل بشكل فعال من تأثير العينات المزعجة على التنبؤات النهائية.

المرونة: تعد خوارزميات التعزيز متعددة الاستخدامات ويمكن استخدامها مع مجموعة متنوعة من النماذج الأساسية ووظائف الخسارة، مما يسمح بالتخصيص والتكيف مع مجالات المشكلات المختلفة. قابلية التفسير: في حين يُشار إلى نماذج التعزيز بشكل متكرر على أنها نماذج "الصندوق الأسود"، إلا أنها يمكن أن توفر بعض القابلية للتفسير من خلال تصنيفات أهمية الميزات، والتي يمكن أن تساعد في فهم القيمة النسبية للميزات المختلفة في عملية التنبؤ.

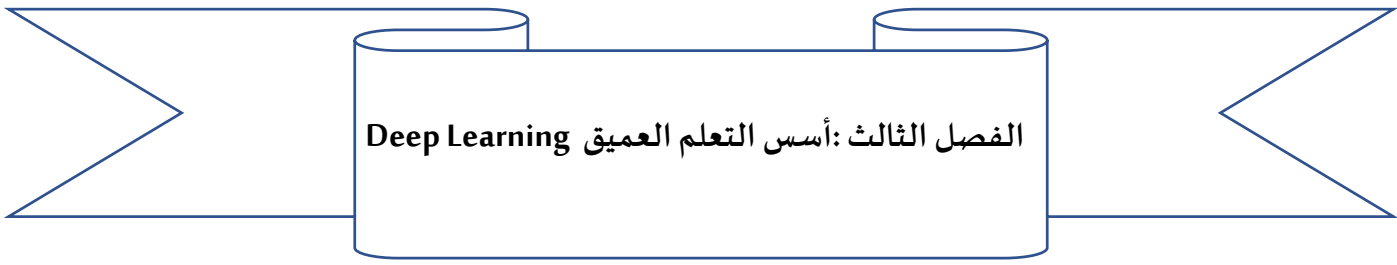
تطبيقات التعزيز : تم استخدام التعزيز بنجاح في مجموعة متنوعة من مهام التعلم الآلي، بما في ذلك: التعرف على الصور والأشياء: تم استخدام التعزيز في تطبيقات رؤية الكمبيوتر لمهام التعرف على الصور والأشياء مثل اكتشاف الوجه والتعرف على الإيماءات واكتشاف الأشياء. قد تنجح الخوارزميات المعززة في تعلم الأنماط المعقدة في الصور وتعزيز دقة نماذج التعرف، مما يؤدي إلى تطبيقات في القياسات الحيوية والمراقبة والمركبات ذاتية القيادة. معالجة النصوص واللغة الطبيعية: تم استخدام التعزيز في مهام مثل تحليل المشاعر وتصنيف النص والتعرف على الكيانات المسماة في معالجة النصوص واللغة الطبيعية. يمكن لتقنيات التعزيز التعامل مع الطبيعة عالية الأبعاد والمتناثرة للبيانات النصية بنجاح، مما يؤدي إلى تحسين أداء النموذج في تطبيقات مثل تحليل مشاعر وسائل التواصل الاجتماعي، واكتشاف البريد العشوائي، وتصنيف النص.

كشف الاحتيال: تم استخدام التعزيز لتحديد الاحتيال في مجموعة متنوعة من الصناعات، بما في ذلك التمويل والتأمين والتجارة الإلكترونية. يمكن أن يؤدي تعزيز خوارزميات إلى الكشف عن أنماط السلوك الاحتمالي في مجموعات البيانات الكبيرة والمعقدة، وتحسين دقة اكتشاف الاحتيال وتقليل الإيجابيات/السلبات الكاذبة في أنظمة كشف الاحتيال.

التشخيص الطبي: تم استخدام التعزيز في مهام التشخيص الطبي مثل تصنيف الأمراض، والتنبؤ بنتائج المريض، وتطوير الأدوية. ومن الممكن أن تتعلم الخوارزميات المعززة من مجموعات البيانات الطبية الكبيرة مثل البيانات السريرية، والتصوير الطبي، والبيانات الجينية لتعزيز دقة التشخيص ونماذج التنبؤ، وبالتالي تمهيد الطريق للطب الشخصي والرعاية الصحية.

أنظمة التوصية: تم استخدام التعزيز في أنظمة التوصية لتقديم اقتراحات مخصصة مثل توصيات المنتجات في التجارة الإلكترونية، وتوصيات الأفلام في منصات البث المباشر، وتوصيات المحتوى في بوابات الأخبار. يمكن للخوارزميات المعززة تسجيل تفضيلات المستخدم وأنماط سلوكه لتقديم اقتراحات دقيقة وزيادة تفاعل المستخدم.

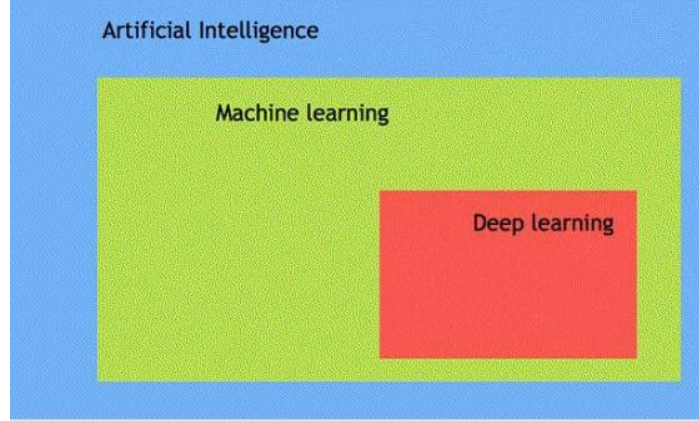
تحليل السلاسل الزمنية: تم استخدام التعزيز في تطبيقات تحليل السلاسل الزمنية مثل التنبؤ بسوق الأوراق المالية، والتنبؤ بالطقس، والتنبؤ بالطلب. يمكن للخوارزميات المعززة التقاط العلاقات والأنماط الزمنية في بيانات السلاسل الزمنية بكفاءة، مما يؤدي إلى تحسين دقة التنبؤ واتخاذ القرار في مجالات مثل التمويل والزراعة وإدارة سلسلة التوريد.



الفصل الثالث: أسس التعلم العميق Deep Learning

مقدمة

التعلم العميق هو فرع من فروع الذكاء الاصطناعي وتعلم الآلة بهدف إيجاد نظريات وخوارزميات تتيح للآلة التعلم من تلقاء نفسها عن طريق محاكاة الخلايا العصبية في جسم الإنسان أي أنها مشابهة تماما للطريقة التي يعمل بها العقل البشري.



التعلم العميق هو برنامج كمبيوتر يحاكي شبكة الخلايا العصبية في المخ. وتسمى التعلم العميق لأنها يستخدم الشبكات العصبية العميقة.


يتم إنشاء خوارزميات التعلم العميق باستخدام طبقات متصلة حيث:

- الطبقة الأولى تسمى طبقة الإدخال .
- الطبقة الأخيرة تسمى طبقة الإخراج
- تسمى جميع الطبقات الموجودة بينهما بالطبقات المخفية. كلمة عميق تعني وتنضم الشبكة إلى الخلايا العصبية في أكثر من طبقتين.

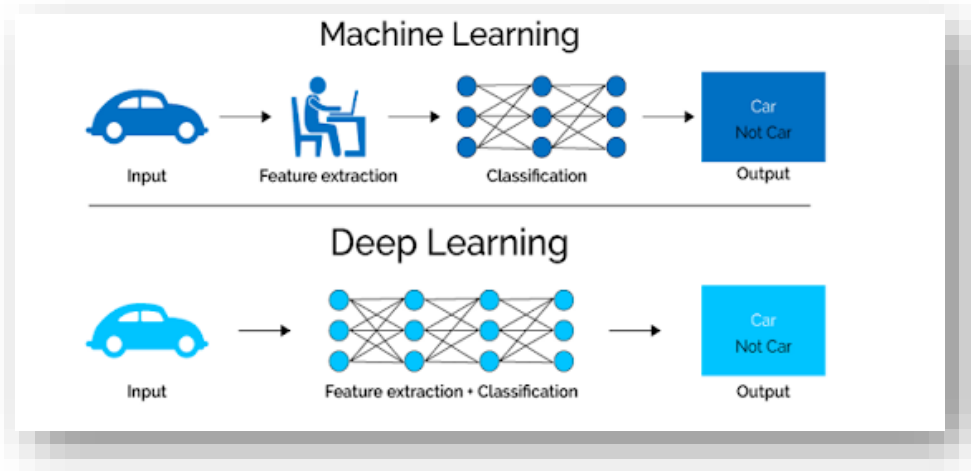
تتكون كل طبقة مخفية من الخلايا العصبية. ترتبط الخلايا العصبية كل منها بالآخر. ستقوم الخلية العصبية بمعالجة ثم نشر إشارة الإدخال التي تستقبلها .

تستهلك الشبكة كميات كبيرة من بيانات الإدخال وتقوم بتشغيلها من خلالها طبقات متعددة؛ يمكن للشبكة أن تتعلم


ميزات البيانات المعقدة بشكل متزايد في كل طبقة



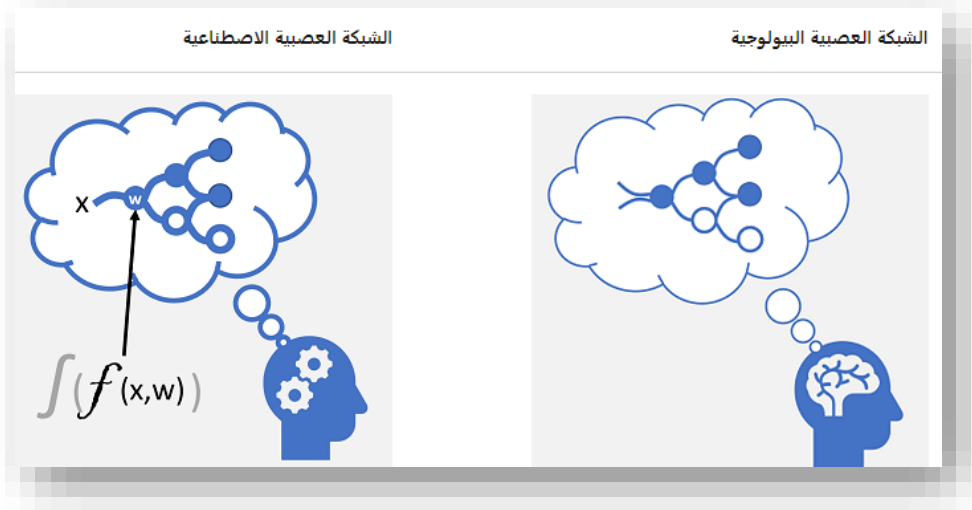
فتختلف تعلم الألة عن التعلم العميق في ان تعلم الالة يتم استخراج الميزات عن طريق المستخدم في تعلم الالي لكن في التعلم العميق عملية استخراج الميزات تعتبر جزء من وظائف الخلايا العصبية الاصطناعية وتقوم بهذه الوظيفة اعتمادا على التعلم من البيئة (محاكاة البيئة).



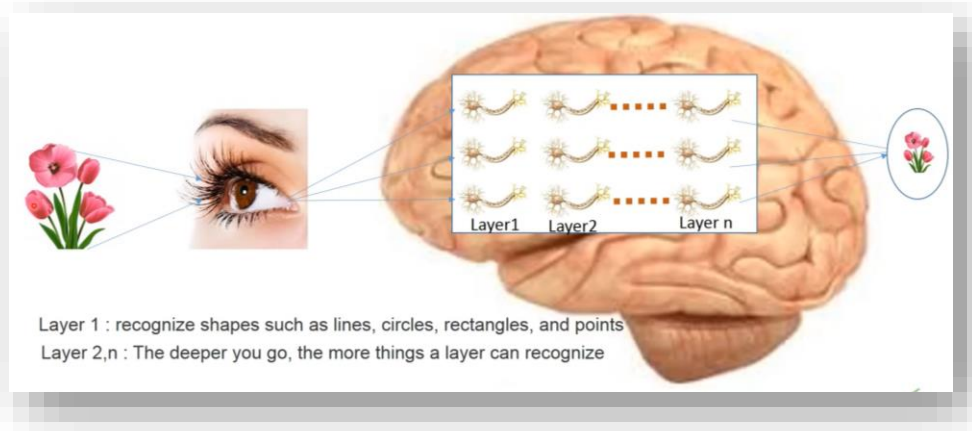
فيستخدم شبكات عصبية مصطنعة لتعليم الأجهزة بطريقة تفاعلية طرق تحسين أدائهم تدريجيا. ويسمح للأجهزة انها تتعرف على الأنماط والمعالم المعقدة في الصور والصوتيات والنصوص، بتدريبهم على مجموعة كبيرة من البيانات



أى أن التعلم العميق هو شكل متقدم من التعلم الالي الذي يحاول محاكاة الطريقة التي يتعلم بها الدماغ البشري. مفتاح التعلم العميق هو إنشاء شبكة عصبية اصطناعية تحاكي النشاط الكهروكيميائية في الخلايا العصبية البيولوجية باستخدام الوظائف الرياضية، كما هو موضح.



فالشبكة العصبية للإنسان يتكون من ملايين الخلايا العصبية التي تتواصل مع بعضها بواسطة الاتصالات العصبية، والشبكة العصبية الاصطناعية تستخدم خطوط اتصال بين الخلايا الاصطناعية. كما أن التعلم في الشبكة العصبية للإنسان يكون عن طريق التجارب والتفاعل مع البيئة، وفي الشبكة العصبية الاصطناعية يكون عن طريق تحليل مجموعة من البيانات المدخلة و التعديل فيها. الشبكة العصبية الاصطناعية تتميز بالقدرة على المعالجة السريعة والدقيقة للبيانات الكبيرة والمعقدة.

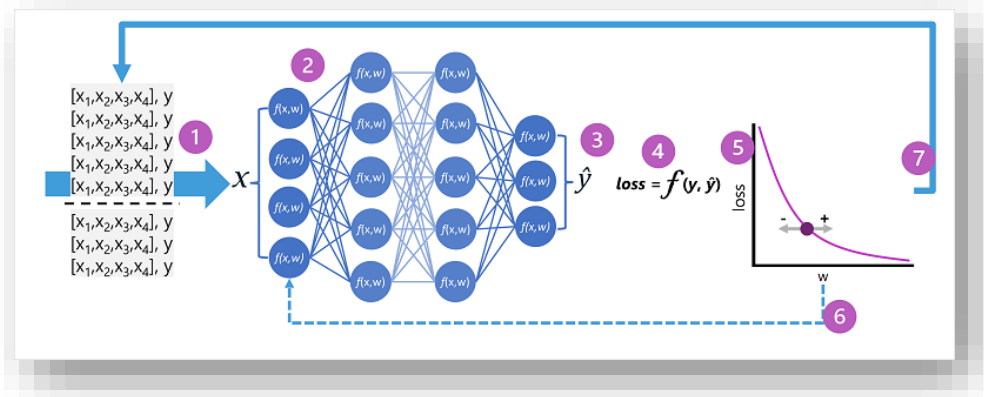


تتكون الشبكات العصبية الاصطناعية من طبقات متعددة من الخلايا العصبية تحدد أساسا وظائف متداخلة بعمق. هذه البنية هي السبب في ظهور وانتشار تقنية التعلم العميق وغالبا ما يشار إلى النماذج التي تنتجها باسم الشبكات العصبية العميقة (DNNs) بحيث يمكن استخدام الشبكات العصبية العميقة لأنواع عديدة من مشكلات التعلم الآلي، بما في ذلك الانحدار والتصنيف، بالإضافة إلى نماذج أكثر تخصصا لمعالجة اللغة الطبيعية ورؤية الكمبيوتر.

آليات العمل بنماذج التعلم العميق مثل تقنيات التعلم الآلي حيث ملاءمة بيانات التدريب للتنبؤ بالتسمية (y) استناداً إلى قيمة ميزة واحدة أو أكثر (x)

كيف تتعلم الشبكة العصبية؟


تعد الأوزان في الشبكة العصبية مركزية لكيفية حساب القيم المتوقعة للتسميات. أثناء عملية التدريب، يتعلم النموذج الأوزان التي ستؤدي إلى التنبؤات الأكثر دقة. فيما يلي خطوات لفهم كيفية حدوث هذا التعلم.



1. يتم تعريف مجموعات بيانات التدريب والتحقق من صحتها، ويتم تغذية ميزات التدريب في طبقة الإدخال.
 2. تطبق الخلايا العصبية في كل طبقة من طبقة الشبكة أوزانها (التي يتم تعيينها بشكل عشوائي في البداية) وتغذي البيانات من خلال الشبكة.
 3. تنتج طبقة الإخراج متجهاً يحتوي على القيم المحسوبة \hat{y} .
 4. تستخدم دالة الخسارة لمقارنة قيم \hat{y} المتوقعة بقيم y المعروفة وتجميع الفرق (الذي يعرف باسم الخسارة).
 5. نظراً لأن الشبكة بأكملها هي في الأساس دالة متداخلة كبيرة، يمكن لدالة التحسين استخدام حساب التفاضلية لتقييم تأثير كل وزن في الشبكة على الخسارة، وتحديد كيفية تعديلها (لأعلى أو لأسفل) لتقليل مقدار الخسارة الإجمالية. يمكن أن تختلف تقنية التحسين المحددة، ولكنها تتضمن عادة نهج هبوط متدرج حيث يتم زيادة كل وزن أو تقليله لتقليل الخسارة.
 6. يتم توفير التغييرات على الأوزان مرة أخرى إلى الطبقات في الشبكة، مع استبدال القيم المستخدمة سابقاً.
 7. تتكرر العملية عبر تكرارات متعددة (تعرف باسم الفترات) حتى يتم تقليل الخسارة ويتنبأ النموذج بدقة مقبولة.
- لفهم مضمون التعلم العميق، ينبغي أن ننطلق من بدايات بسيطة وسهلة. وعلى تلك البدايات سنبنى صورة أكثر تعقيداً وتفصيلاً؛ إلى أن نتمكن، من فهم ما تعنيه كلمة «عميق» في مصطلح التعلم العميق.

الخلايا العصبية، الحقيقية والاصطناعية

سنبدأ من حجر الزاوية الأساسي لأنظمة التعلم العميق، القادم من علم الأحياء. الدماغ جزء من الجهاز العصبي، والمكونات الأساسية للجهاز العصبي عبارة عن خلايا تسمى الخلايا العصبية. تتميز الخلايا العصبية بشكل خاص؛ فهي تبدو مختلفة في الشكل عن البنى الكروية التي عادةً ما نربطها بالخلايا. وفيما يلي واحدة من أولى صور الخلايا العصبية، رسمها العالم الإسباني سانتياجو رامون إي كاخال عام ١٨٩٩، أحد مؤسسي علم الأعصاب الحديث.




كما ترى، تتكوّن الخلية العصبية من جسم الخلية والخيوط التي تنبثق منها. تربط هذه الخيوط الخلية العصبية بخلايا عصبية أخرى عبر «تشابكات عصبية» بطريقة تدمج الخلايا العصبية في شكل شبكة. الخلايا العصبية غير متماثلة. فيوجد العديد من الخيوط في جانب وخط واحد فقط في الجانب الآخر لكل خلية عصبية. يمكننا القول إن الخيوط العديدة في الجانب الأول تمثّل مدخلات الخلية العصبية، والخيوط الطويل الخارج من الجانب الآخر يمثّل مخرج الخلية العصبية. تستقبل الخلية العصبية المدخلات في شكل إشارات كهربائية من تشابكاتها العصبية الواردة وقد ترسل إشارة إلى الخلايا العصبية الأخرى. وكلما زادت الإشارات الواردة، زاد احتمال أن ترسل هي إشارة. عندئذٍ نقول إن الخلية العصبية «محفزة» أو «نشطة».

الخوارزميات تأليف بانوس لوريداس ترجمة إبراهيم سند أحمد مراجعة شيماء طه الريدي؛ 2017 م.

الدماغ البشري يتكون من شبكة ضخمة من الخلايا العصبية، ويقدر عددها بحوالي مائة مليار خلية، حيث تتصل كل خلية بألاف الخلايا العصبية الأخرى في المتوسط. بالرغم من عدم توفر الوسائل لبناء شبكة بهذا الحجم، يمكننا إنشاء أنظمة مستمدة من نماذج مبسطة ومثالية للخلايا العصبية.

في هذا السياق، يتم تقديم نموذج لخلية عصبية اصطناعية كنموذج تجريدي للخلية العصبية الحيوية. يتألف هذا النموذج من مجموعة معينة من المدخلات ومخرج واحد.




يتوقف مخرج الخلية العصبية الحيوية على المدخلات التي تتلقاها، وعلى نفس النحو، يهدف تنشيط الخلية العصبية الاصطناعية إلى الاعتماد على مدخلاتها. ولكن لتحقيق هذا، يجب أن يتوافر لدينا نموذج حوسبي للخلية العصبية الاصطناعية.

لنفترض أن الإشارات التي تستقبلها الخلايا العصبية وترسلها عبارة عن أرقام. عندئذٍ، تأخذ الخلية العصبية الاصطناعية كل المدخلات وتحسب قيمةً حسابيةً ما بناءً على تلك المدخلات، وتخرج لنا بنتيجةً ما على مخرجها. لا نحتاج إلى أي دائرة خاصة لتنفيذ خلية عصبية اصطناعية. يمكنك تخيلها كبرنامج صغير على جهاز كمبيوتر يستقبل المدخلات ويحولها إلى مخرجات، مثل أي برنامج آخر على الكمبيوتر. لسنا بحاجة إلى بناء شبكات عصبية اصطناعية بالمعنى الحرفي؛ بل يمكننا محاكاتها وهذا ما يقوم به بالفعل التعلم العميق.


جزء من عملية التعلم في الشبكات العصبية البيولوجية يكمن في تقوية التشابكات العصبية بين الخلايا العصبية أو إضعافها. فإكتساب قدرات معرفية جديدة واستيعاب المعلومات يؤديان إلى تقوية بعض التشابكات العصبية بين الخلايا العصبية، بينما يؤدي ذلك إلى إضعاف خلايا أخرى أو حتى إخمادها بالكامل. إضافة إلى ذلك، قد لا تؤدي التشابكات العصبية إلى تحفيز الخلية العصبية فحسب، بل إلى تثبيط نشاطها؛ وعندما تصل إشارة إلى ذلك التشابك، لا تحفز تلك الخلية العصبية. ولدى الأطفال الرضع تشابكات عصبية في أدمغتهم أكثر من الكبار. وتشذيب الشبكات العصبية داخل أدمغتنا جزء من النمو. ربما يمكن تشبيهه دماغ الطفل الرضيع بكتلة من الرخام؛ كلما مرّت علينا السنين، تُشَدَّب تلك الكتلة جراء التجارب والأشياء التي نتعلمها، ويظهر لها شكل محدد.

في الخلية العصبية الاصطناعية، نُقدِّر مرونة التشابكات العصبية ودورها المحفز أو المثبط من خلال «أوزان» نخصصها للمُدخلات. في نموذج الخلية العصبية الاصطناعية، لدينا n من المدخلات x_1, x_2, \dots, x_n نخصِّص لكل مُدخل منها وزناً w_1, w_2, \dots, w_n . يُضرب كل وزن في المدخل الموازي له. المُدخل الأخير الذي تستقبله الخلية العصبية هو مجموع حواصل ضرب $w_1x_1 + w_2x_2 + \dots + w_nx_n$ نضيف لهذا المُدخل الموزون الانحياز b ، الذي يمكنك اعتباره الزعة الطبيعية لدى الخلية العصبية للاستثارة أو التحفيز؛ وكلما زاد الانحياز، زاد ميلها إلى النشاط، بينما سيؤدي إضافة انحياز سلبي إلى الإدخال الموزون إلى تثبيط الخلية العصبية وعزوفها عن الاستثارة.

تعد قيم الأوزان والانحياز «معاملات» الخلية العصبية لأنها تؤثر في سلوكها. ولما كانت مخرجات الخلية العصبية الحيوية تعتمد على مدخلاتها، فإن مخرجات الخلية العصبية الاصطناعية تعتمد على المدخلات التي تستقبلها. وتتم تلك العملية عن طريق تغذية المدخلات في دالة تنشيط خاصة، التي تكون نتيجتها هي مخرجات الخلية العصبية. وهذا ما يحدث، على المستوى البياني، باستخدام الدالة $f(0)$ كبديل لدالة التنشيط.



أبسط دالة تنشيط عبارة عن دالة درجية، تعطينا النتيجة 0 أو 1. تُحفّز الخلية العصبية وتعطي النتيجة 1 إذا كان المدخل إلى دالة التنشيط أكبر من صفر، أو تبقى النتيجة ثابتة على صفر إذا كان المدخل غير ذلك:




بدلاً من التفكير في الانحياز، من المفيد أن نفكر في حدّ. تعطي الخلية العصبية النتيجة 1 إذا كانت المدخلات الموزونة أعلى من الحد، وإذا كانت غير ذلك فستكون النتيجة صفراً. في الحقيقة، إذا كتبنا سلوك الخلية العصبية في شكل صيغة، تكون الحالة الأولى هي $(w_1x_1 + w_2x_2 + \dots + w_nx_n + b > 0)$ أو $(w_1x_1 + w_2x_2 + \dots + w_nx_n > -b)$ وباستخدام $a = -b$ ، نحصل على النتيجة $(w_1x_1 + w_2x_2 + \dots + w_nx_n > t)$ ، حيث t معكوس الانحياز هي الحد الذي تحتاج المدخلات الموزونة إلى تمييزه إلى الخلية العصبية لتحفيزها.

هناك ثلاث دوال شائعة أخرى غير الدالة الدرجية السابقة يمكن توضيحها على النحو التالي :

الدالة السينية: لأنها تأخذ شكل حرف s وتتراوح مخرجاتها من صفر إلى 1 فالمدخلات الكبيرة الموجبة تعطي مخرجات قريبة من 1، والمدخلات الكبيرة السالبة تعطي مخرجات قريبة من صفر. وهذا يقارب خلية عصبية حيوية تُحفّز مع المدخلات الكبيرة وتبقى ثابتة إذا كانت غير ذلك، كما أنها تعتبر تقريب سلس إلى الدالة الدرجية.

دالة الظل الزائدي: وهي تشبه الدالة السينية، ولكنها تختلف في أن مخرجها يتراوح بين -1 و $+1$ ؛ إذ تؤدي المدخلات الكبيرة السالبة إلى نتيجة سالبة


دالة المصحح: إذ تحول كل المدخلات السالبة إلى صفر، وإلا فسيتناسب مخرجها طرديًا مع مدخلاتها. يوضح الجدول التالي مخرجات دوال التنشيط الثلاث لمدخلات مختلفة.



ولكن ما هو سبب انتشار دوال التنشيط في ظل وجود دوال غيرها؟ الاجابة عن هذا التساؤل تكمن في أنه ثبت عمليًا أن بعض دوال التنشيط أنسب في بعض التطبيقات من غيرها. ولما كانت دالة التنشيط بالغة الأهمية بالنسبة إلى الخلية العصبية، فغالبًا ما تسمى الخلايا العصبية باسم دوال التنشيط الخاصة بها. فالخلية العصبية التي تستخدم الدالة الدرجية تسمى

«بيرسيبترون» إذن، لدينا الخلية العصبية السينية والخلية العصبية ذات الظل الزائدي. كذلك نطلق على الخلايا العصبية «وحدات»، بينما تسمى الخلية العصبية التي تستخدم دالة المصحح الوحدة الخطية المصححة (أو ريلو).

يمكن أن تتعلم الخلية العصبية الاصطناعية الفردية التمييز بين مجموعتين من العناصر؛ على سبيل المثال، لنأخذ البيانات في الصورة الأولى فيما يلي التي تصوّر مجموعة من الملاحظات بعلامتين، x_1 على المحور الأفقي و x_2 على المحور الرأسى. نريد أن نبني نظامًا يستطيع التفريق بين مجموعتي النقاط. بناءً على أي عنصر، سيتمكن النظام من تحديد إذا ما كان العنصر يقع في إحدى المجموعتين أو الأخرى. في الواقع، سينشئ النظام «حدًا للقرار»، كما في الشكل الثاني. بالنسبة إلى أي مجموعة مكونة من (x_1, x_2) ، سيخبرنا النظام إذا ما كان العنصر ينتهي إلى المجموعة ذات اللون الفاتح أم ذات اللون القاتم.



لن تتضمن الخلية العصبية أكثر من مدخلين. ستأخذ كل زوج (x_1, x_2) وتحسب مخرجًا. إذا كنّا نستخدم دالة التنشيط السينية، فسيتراوح المخرج بين (0 و 1) ستأخذ القيم الأكبر من 0.5 وندرجها في إحدى المجموعتين ونأخذ القيم الباقية وندرجها في المجموعة الأخرى. بهذه الطريقة، سوف تعمل الخلية العصبية كمصنف، يصنف البيانات إلى فئتين مختلفتين. ولكن كيف تفعل ذلك؟ كيف يمكن للخلية العصبية أن تصل إلى مرحلة القدرة على تصنيف البيانات؟

عملية التعلم:

في لحظة إنشاء الخلية العصبية، لا تتمكّن الخلية من التعرّف على أي نوع من البيانات؛ بل تتعلّم التعرّف على البيانات. ويتم هذا التعلّم بطريق الأمثلة.

العملية برمتها تشبه تعليم الطالب درسًا جديدًا بإعطائه مجموعة كبيرة من المسائل عن موضوع ما مصحوبة بالحلول. نطلب من الطالب أن يذاكر كلّ مسألة وحلها. إذا كان الطالب مجتهدًا، فإننا نتوقّع أن يتعلم كيفية الانتقال من المسألة إلى الحل بعد الاطلاع على عددٍ من المسائل، بل يتمكّن من حل مسائل جديدة ذات صلة بالمسائل التي درسها، ولكنه سيحلها هذه المرة من دون أن يلجأ إلى أي حلول.

عندما نقوم بذلك، فإننا ندرّب الكمبيوتر على إيجاد الحلول؛ ويطلق على مجموعة المسائل النموذجية المحلولة «مجموعة بيانات التدريب». ويُعد هذا مثالًا على «التعلم الموجّه»؛ لأنّ الحلول توجّه جهاز الكمبيوتر مثل المشرف نحو البحث عن الإجابات الصحيحة.

والتعلم الموجّه هو الشكل الأكثر شيوعًا من أشكال تعلّم الآلة، وهو الفرع الذي يتعامل بالكامل مع طرقٍ ندرّب من خلالها أجهزة الكمبيوتر على إنجاز المهام.

يشتمل تعلّم الآلة على التعلم غير الموجّه أيضا، حيث نزوّد جهاز الكمبيوتر بمجموعةٍ من بيانات التدريب ولكن دون إرفاق أي حلول معها. توجد تطبيقات مهمة للتعلم غير الموجّه، ومنها على سبيل المثال تجميع الملاحظات في مجموعات مختلفة؛ (لا يوجد حل مسبق يشير إلى ماهية المجموعة الصحيحة).

التعلم الموجّه بالخلايا العصبية الاصطناعية:

في لحظة إنشاء الخلية العصبية، لا تتمكّن الخلية من التعرّف على أي نوع من البيانات؛ بل تتعلم التعرّف على البيانات. ويتم هذا التعلّم بطريق الأمثلة.

بعد التدريب، غالبًا ما يمر الطالب ببعض الاختبارات للوقوف على مدى إتقانه للمادة. بالمثل، في تعلّم الآلة، نعطي جهاز الكمبيوتر بعد التدريب مجموعة بيانات أخرى لم يرّها من قبل ونطلب منه حل «مجموعة بيانات الاختبار» تلك. بعد ذلك نقيّم أداء نظام تعلّم الآلة بناءً على مدى إجادته لحل المسائل في مجموعة بيانات الاختبار.

في مهمة التصنيف، يسير التدريب في التعلّم الموجّه بإعطاء الشبكة العصبية عددًا كبيرًا من الملاحظات (التساؤلات) ومعها الفئات الخاصة بها (الحلول). ونتوقّع أن تتعلم الخلية العصبية بصورة أو بأخرى كيفية الانتقال من ملاحظة ما إلى التصنيف الخاص بها. عندئذٍ إذا أعطيناها ملاحظة لم ترّها من قبل، يفترض أن تصنّفها بقدرٍ معقول من النجاح.

يتحدّد سلوك الخلية العصبية تجاه أي مدخل حسب أوزانه وانحيازه. عندما نبدأ، نضع الأوزان والانحياز بقيم عشوائية، دون أن تعلم الخلية العصبية شيئًا عنها، مثل طالب جاهل بلا أي معلومات. ثم نعطي الخلية العصبية مدخلًا واحدًا في شكل مجموعة زوجية (x1، x2). ستنتج الخلية العصبية مُخرَجًا؛ بما أن لدينا قيم أوزان وانحياز عشوائية، ستكون المخرجات أيضًا

عشوائية. لكننا نعلم الإجابة الصحيحة التي ينبغي أن تصدر من الخلية العصبية بالنسبة إلى كل ملاحظة من الملاحظات في مجموعة بيانات التدريب. عندئذٍ، يمكننا حساب مدى بُعد مخرجات الخلية العصبية عن المخرجات المطلوبة. ويُطلق على تلك النتيجة «الخسارة» وهي قياس درجة خطأ الخلية العصبية بالنسبة إلى مُدخل معيّن.

على سبيل المثال، إذا نتج عن مدخلات الخلية العصبية مخرجًا قيمته (٠,٢) في حين أن المخرج المطلوب هو (١,٠) يمكننا حساب الخسارة عن طريق طرح القيمتين إحداهما من الأخرى.

وتجنبًا للاضطرار إلى التعامل مع العلامات، عادةً ما نعتبر الخسارة تربيع ناتج الطرح؛ وفي هذا المثال ستكون $(٠,٢ - ١,٠) = ٠,٦٤$.

وإذا كان المخرج المطلوب (٠,٠) عندئذٍ ستصبح الخسارة $(٠,٢ - ٠,٠) = ٠,٠٤$.

، يمكننا الآن، بعد أن حسبنا الخسارة، تعديل الأوزان والانحياز لتقليلها.

نعود إلى الطالب، بعد كل محاولة فاشلة لحل تمرين ما، نحته على تقديم أداء أفضل. يكتشف الطالب أن عليه تغيير طريقته قليلاً ويحاول في المثال التالي. إذا فشل، نحته مرة أخرى. ثم مرة أخرى. وبعد العديد من الأمثلة في مجموعة بيانات التدريب، سيبدأ في تصحيح الأمور أكثر وأكثر وسيتمكن من التعامل مع مجموعة بيانات الاختبار.

عندما يتعلم الطالب، يخبرنا علم الأعصاب أن الموصلات داخل الدماغ تتغير؛ فتقوى بعض التشابكات العصبية بين الخلايا العصبية وبعضها يضعف وبعضها الآخر يموت. لا يوجد مكافئ مباشر للخلية العصبية الاصطناعية، ولكن يحدث شيء مماثل. تذكّر مرة أخرى أن سلوك الخلية العصبية يعتمد على مدخلاتها وأوزانها وانحيازها. ليس لدينا تحكّم في المدخلات لأنها تأتي من البيئة. ولكن يمكننا تغيير قيم الأوزان والانحياز. وهذا ما يحدث في الحقيقة. فنحن نُحدّث قيم الأوزان والانحياز بطريقة تجعل الخلية العصبية تقلّل من أخطائها.

الطريقة التي نستخدمها الخلية العصبية لتحقيق ذلك هي الاستفادة من ميزة طبيعة المهمة المطلوبة بإنجازها. فنحن نريدها أن تأخذ كل ملاحظة وتحسب مخرجًا وفقًا للفئة، وتعدل أوزانها وانحيازها لتقليل الخسارة. إذن، تحاول الخلية العصبية حلّ مسألة من مسائل «الحد الأدنى». بناءً على المدخلات والمخرجات التي تنتجها، تكون المسألة هي كيف لنا أن نعيد معايرة الأوزان والانحياز لتقليل الخسارة؟


فيما سبق وصفنا الخلية العصبية بأنها شيء يأخذ بعض المدخلات ويحوّلها إلى مخرج. إذن فالخلية العصبية بهذا المعنى، هي عبارة عن دالة كبيرة تأخذ مدخلاتها وتطبّق قيم الأوزان وتجمع حواصل الضرب وتجمع الانحياز وتمرّر النتيجة عبر دالة التنشيط ثم تعطي المخرج النهائي. ولكن إذا فكّرنا بطريقة أخرى، نجد أن المدخلات والمخرجات محدّدة بالفعل (تلك هي مجموعة بيانات التدريب)، بينما ما يمكننا تغييره هو الأوزان والانحياز. ومن ثمّ يمكننا اعتبار الخلية العصبية بأنها دالة تتكوّن متغيراتها من «الأوزان والانحياز»؛ لأننا لا نستطيع التأثير إلا في هذه القيم، ونريد أن نغيّرها مع كل مُدخل للحد من الخسارة.

على سبيل المثال إذا أخذنا خلية عصبية بسيطة، لها وزن واحد وليس لها انحياز، فقد تكون العلاقة بين الخسارة والوزن كما كما موضح بالشكل أدناه في الجزء الأيسر؛ ليوضح المنحنى السميكة الخسارة في صورة دالة وزن مُدخل معيّن. ينبغي أن تعديّل الخلية العصبية وزنها بحيث تصل إلى أقل قيمة للدالة. بالنسبة إلى المدخل المعطى، تشتمل الخلية العصبية حاليًا على خسارة في النقطة المشار إليها.

الجدير بالذكر أن الخلية العصبية لا تعرف الوزن المثالي الذي من شأنه تقليل الخسارة لكن الشيء الوحيد الذي تعرفه هو قيمة الدالة عند النقطة المشار إليها وقد لا تعديّل الخلية العصبية الوزن إلا بقدر ضئيل سواء بزيادة القيمة أو خفضها بحيث تقترب من الحد الأدنى.

ولمعرفة ما ينبغي فعله، سواء برفع قيمة الوزن أو خفضها، من الممكن أن توجد الخلية العصبية خطّ المماس عند النقطة الحالية. بعد ذلك يمكنها حساب ميل خط المماس؛ وهي الزاوية مع المحور الأفقي الموضحة أيضًا في الشكل. لاحظ أن الخلية العصبية يمكنها إجراء تلك العملية الحسابية دون أي إمكانيات خاصة سوى قدرتها على تنفيذ عمليات حسابية عند النقطة الموضعية.

ميل خط المماس سالب؛ لأن الزاوية في اتجاه دوران عقارب الساعة. يوضح الميل «معدل التغيير في الدالة»؛ ومن ثم يشير الميل السالب إلى أنه مع زيادة الوزن، تقل الخسارة. عندئذٍ تكتشف الخلية العصبية أنه لتقليل الخسارة، ينبغي أن تتحرك إلى اليمين. وبما أن الميل سالب والتغيير المطلوب في الوزن موجب، تجد الخلية العصبية أنه لا بد من تحريك الوزن في اتجاه موجب؛ أي اتجاه معاكس لما يشير إليه الميل.



ننتقل الآن إلى الشكل جهة اليمين في الشكل السابق. تقع الخلية العصبية هذه المرة جهة اليمين من الحد الأدنى للخسارة. تأخذ الخلية خطّ المماس مرة أخرى وتحسب ميله. قيمة الزاوية موجبة، ومن ثم تكون قيمة الميل موجبة أيضًا. يشير الميل الموجب إلى أن زيادة الوزن تؤدي إلى زيادة الخسارة. عندئذٍ تعلم الخلية العصبية أنه يتعيّن خفض قيمة الوزن لتقليل الخسارة. وبما أن الميل موجب والتغيير المطلوب في الوزن سالب، تجد الخلية العصبية مرة أخرى ضرورة التحرك في الاتجاه المعاكس للاتجاه الذي يشير إليه الميل.

لا تحتوي الخلية العصبية عادةً على وزن واحد، بل على عدة أوزان بالإضافة إلى الانحياز. ولمعرفة كيفية تعديل كل وزن على حدة وتعديل الانحياز، تبدأ الخلية العصبية مثلما ذكرنا في مثال الوزن الواحد. بمصطلحات رياضية، تحسب الخلية ما يسمّى بـ «المشتقة الجزئية» للخسارة بالنسبة إلى كل وزن فردي والانحياز. بالنسبة إلى العدد n من الأوزان والانحياز، ستكون $n+1$ من المشتقات الجزئية إجمالاً. يطلق على المتجه الذي يتضمّن كل المشتقات الجزئية للدالة اسم «تدرّج» الدالة. والتدرّج هو مرادف الميل عندما يكون لدينا دالة متعددة المتغيرات؛ إنه يحدد الاتجاه الذي ينبغي أن نتبعه لزيادة قيمة الدالة. ولتقليل قيمة الدالة، نسير في الاتجاه المعاكس. لذا لتقليل الخسارة، تحدّث الخلية العصبية كل وزن والانحياز في الاتجاه المعاكس لما تشير إليه المشتقات الجزئية التي تشكّل تدرّجها.

في الحقيقة لا تُجرى العمليات الحسابية برسم خطوط المماس وقياس الزوايا. توجد طرق فعّالة لإيجاد المشتقات الجزئية والتدرّج، ولكن لا داعي للخوض في تفاصيلها في الوقت الحالي. المهم هو أن لدينا طريقة محدّدة لتعديل الأوزان والانحياز من أجل تحسين نتائج الخلية العصبية. وبذلك، يمكن وصف عملية التعلم بالخوارزمية التالية:

بالنسبة إلى كل مدخل وكل مُخرج مطلوب في مجموعة بيانات التدريب:

(١) يُحسب مُخرج الخلية العصبية والخسارة.


(٢) تُحدّث قيم الأوزان والانحياز للخلية العصبية لتقليل الخسارة.

بمجرد الانتهاء من التدريب بالاطلاع على كل البيانات المدرجة في مجموعة بيانات التدريب، نقول إننا قد أكملنا «مرحلة». لكننا لا نتوقّف عند هذا الحد عادةً. فالعملية تُعاد كاملة عدة مرات؛ إن الأمر أشبه بالطالب حينما يعيد مذاكرة المادة كلها من جديد بعد الاطلاع عليها كاملة. ومن المتوقع أن يحرز تحسّناً في المرة القادمة؛ لأنه هذه المرة لا يبدأ من الصفر إذ لم يُعد جاهلاً بالمادة لأنه تعلّم شيئاً بالفعل من المرحلة السابقة.

كلما كررنا التدريب بإضافة مراحل إلى نظام التدريب، يزيد الفهم لبيانات التدريب. لكن الإفراط في التدريب قد يكون شيئاً سيئاً. فالطالب الذي يدرّس مجموعة المسائل نفسها مراراً ربما سيتعلم حلّها من جذورها، دون أن يعرف كيفية حل أي مسائل أخرى لم يسبق أن تعرّض لها. نرى ذلك يحدث عندما يفشل طالب يبدو مستعداً جيداً فشلاً ذريعاً في الامتحانات. في تعلّم الآلة، عندما ندرّب الكمبيوتر على مجموعةٍ معينة من بيانات التدريب، نقول إن التدريب «مناسب» للبيانات. أما التدريب المفرط فيؤدّي إلى ما يسمّى «فرط الاستعداد»: أي الإتيان بأداء ممتاز في مجموعة بيانات التدريب وأداء سيئ في مجموعة بيانات الاختبار.

الخلية العصبية، باتباع هذه الخوارزمية، يمكن أن تتعلّم تصنيف أي بيانات «يمكن الفصل بينها خطياً». إذا كان للبيانات بُعدان، فهذا يعني أنه ينبغي الفصل بينها بخط مستقيم. أما إذا كان للبيانات سماتٌ أخرى، وليس فقط (x_1, x_2) ، فيُعمّم المبدأ. بالنسبة إلى البيانات الثلاثية الأبعاد أي ثلاثة مدخلات (x_1, x_2, x_3) يمكن الفصل بينها خطياً إذا كان يمكن الفصل بينها بمستوى بسيط في الفضاء الثلاثي الأبعاد. أما حال وجود مزيد من الأبعاد، فنطلق على المكافئ للخط والمستوى اسم «المستوى الفائق».

في نهاية التدريب، تكون الخلية العصبية قد تعلّمت الفصل بين البيانات. وكلمة «تعلّمت» هنا تعني أن الخلية العصبية وجدت الأوزان والانحياز المناسبين بالطريقة التي ذكرناها؛ أي بدأت بقيم عشوائية ثم حدّثتها تدريجيًّا؛ ومن ثم قلّت الخسارة.

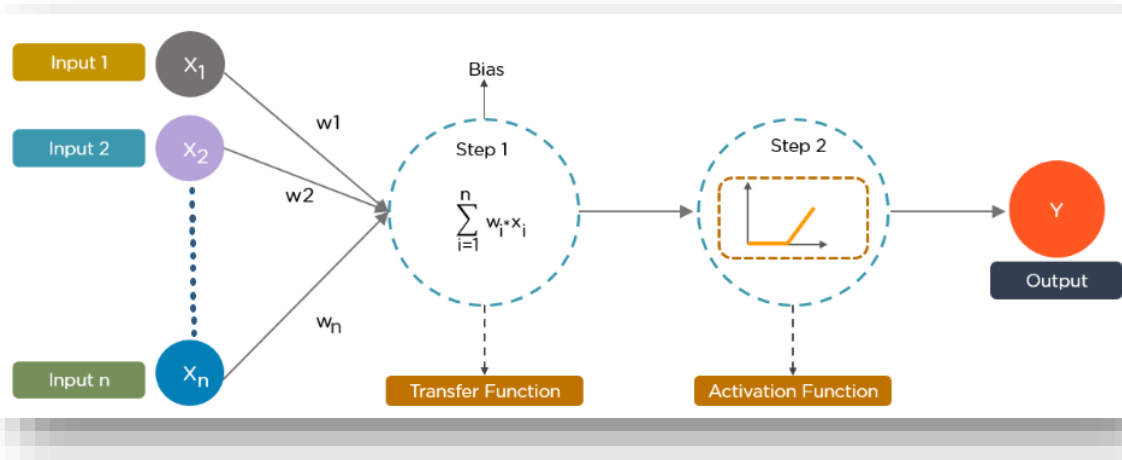


لا يحدث هذا دومًا. فالخلية العصبية المفردة التي تعمل بمفردها يمكنها تنفيذ مهامّ محدّدة فقط، مثل تصنيف البيانات القابلة للفصل خطيًّا. وللتعامل مع مهامّ أعمد، نحتاج أن ننتقل من خلية عصبية اصطناعية وحيدة إلى شبكات الخلايا العصبية.

الشبكات العصبية الاصطناعية:


تكون الشبكة العصبية مثل الدماغ البشري من خلايا عصبية اصطناعية (artificial neuron)، تُعرف أيضًا باسم العقد (node). هذه العقد مكدسة بجانب بعضها البعض في ثلاث طبقات:

- طبقة الادخال Input Layer
- الطبقة المخفية Hidden Layer
- طبقة الاخراج Output Layer



توفر البيانات لكل عقدة (node) معلومات في شكل مدخلات (inputs) تضاعف العقدة المدخلات بأوزان عشوائية وتحسبها وتضيف انحيازًا (bias). أخيرًا، يتم تطبيق الدالات غير الخطية، والمعروفة أيضًا باسم دالات التفعيل (activation functions)، لتحديد أي خلية عصبية (neuron) يجب إطلاقها.

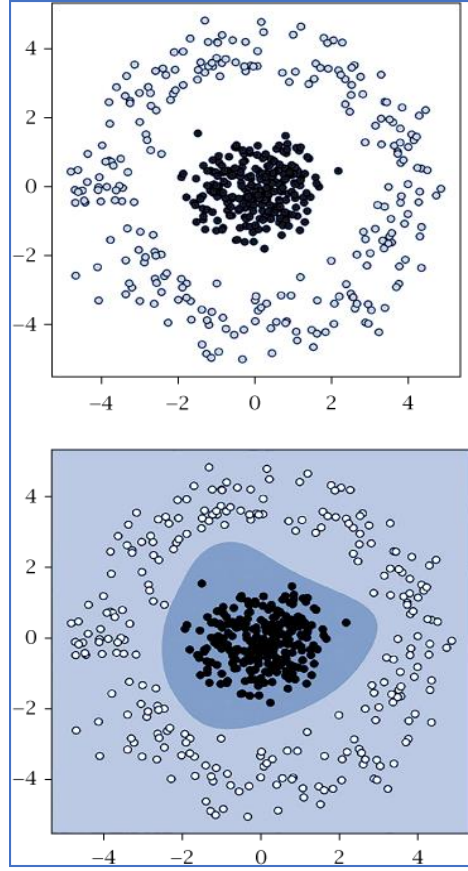
فالامر مثله كما في الشبكات العصبية الحيوية، يمكننا بناء شبكة عصبية اصطناعية من خلايا عصبية مترابطة. يمكن ربط إشارات المدخلات لخلية عصبية بمخرجات خلايا عصبية أخرى، ويمكن أن ترتبط إشارة مخرجاتها بمدخلات خلايا عصبية أخرى. بهذه الطريقة يمكننا إنشاء شبكات عصبية كالتالية:



تُرتَّب الخلايا العصبية لهذه الشبكة العصبية الاصطناعية في شكل طبقات. وغالبًا ما يكون هذا هو المتَّبَع في التطبيق العملي؛ حيث يتشكَّل العديد من الشبكات العصبية التي ننشئها من طبقات من الخلايا العصبية، كل طبقة بجوار الطبقة السابقة لها. كذلك جعلنا كل الخلايا العصبية في إحدى الطبقات متصلةً بكل الخلايا العصبية في الطبقة التالية، مع التحرك من اليسار إلى اليمين. مرة أخرى، تلك الطريقة شائعة على الرغم من عدم ضرورتها. عندما يكون لدينا طبقات متصلة بتلك الطريقة، نطلق عليها «طبقات كثيفة الاتصال».

على الرغم من أن الطبقة الأولى ليست متصلة بأي طبقة سابقة، فإن مخرجات الطبقة الأخيرة ليست مرتبطة بأي طبقة لاحقة بالمثل. فمخرجات الطبقة الأخيرة هي مخرجات الشبكة ككل؛ ومن ثمَّ سوف توفَّر القيم التي نريد حسابها.


لنرجع إلى مهمة التصنيف. تدور المسألة الآن حول الفصل بين مجموعتين من البيانات موضحتين في الشكل العلوي ممَّا يلي. تقع البيانات في دوائر متحدة المركز. واضح للجميع أن البيانات تنتمي لمجموعتين مختلفتين. وواضح أيضًا أنه لا يمكن فصل المجموعتين خطيًا؛ فلا يمكن لخطٍ مستقيم أن يفصل بين الفئتين. لذا نريد إنشاء شبكة عصبية تستطيع التمييز بين المجموعتين بحيث نخبرنا إلى أي مجموعة ستنتهي أي ملاحظة مستقبلية. هذا ما تراه في الشكل السفلي. بالنسبة إلى أي ملاحظة في الخلفية ذات اللون الفاتح، ستدرك الشبكة العصبية أنها تنتمي إلى إحدى المجموعتين؛ وبالنسبة إلى أي ملاحظة في الخلفية ذات اللون القاتم، ستخبرنا أنها تنتمي إلى المجموعة الأخرى.



للوصول إلى النتائج التي نراها في الشكل الاسفل نتبع الاتى :


- نبنى شبكة طبقة تلو الأخرى.
- نضع خليتين عصبيتين في طبقة المدخلات، خلية لكل إحدائى للبيانات.
- نضيف طبقةً من أربع خلايا عصبية كثيفة الاتصال بطبقة المدخلات. ونظرًا لأن هذه الطبقة ليست متصلة بالمدخلات أو المخرجات، فتكون طبقة مخفية.
- نضيف طبقةً مخفية من خليتين عصبيتين مكثفة الاتصال بالطبقة المخفية الأولى.
- ننهي بناء الشبكة بطبقة مخرجات مكونة من خلية عصبية واحدة وكثيفة الاتصال بالطبقة المخفية الأخيرة.

- كل الخلايا العصبية تستخدم دالة التنشيط ذات الظل الزائدي. ستخرج طبقة المخرجات قيمة تتراوح بين -1 و+1، عارضة بذلك اعتقادها بأن البيانات تقع ضمن إحدى المجموعتين أو الأخرى.
- نأخذ تلك القيمة ونحوّلها إلى قرار ثنائي إجابة تحتل نعم أو لا بناءً على إذا ما كانت تتجاوز 0.0، أم لا.




خوارزمية الانتشار العكسي:

في البداية، لا تعرف الشبكة العصبية شيئاً، ولا يحدث تعديل؛ ومن ثم نبدأ بأوزان وانحيازات عشوائية. بعد ذلك نعطي الشبكة العصبية ملاحظة من البيانات التي معنا؛ أي مجموعة من الإحداثيات. سينتقل الإحداثيان x_1 و x_2 إلى طبقة المدخلات. تأخذ كلتا الخليتين العصبيتين القيم x_1 و x_2 وتمررناهما باعتبارهما مخرجاتهما إلى الطبقة المخفية الأولى. تحسب الخلايا العصبية الأربع في تلك الطبقة جميعاً مخرجاتها، وترسلها إلى الطبقة المخفية الثانية كل في دورها. ترسل الخلايا العصبية في تلك الطبقة مخرجاتها إلى الخلية العصبية في طبقة المخرجات، التي تنتج قيمة المخرجات النهائية للشبكة العصبية. مع تقدّم العمليات الحسابية من طبقة إلى أخرى، تنشر الشبكة العصبية نتائج الخلايا العصبية للأمام من طبقة المدخلات إلى طبقة المخرجات:



بمجرد الوصول إلى طبقة المخرجات، نحسب الخسارة مثلما فعلنا مع الخلية العصبية المفردة. وعندئذٍ لا نعدّل قيم الأوزان والانحياز لخلية عصبية واحدة فحسب، بل للخلايا العصبية كافة في الشبكة من أجل تقليل الخسارة.

يتبيّن أنه يمكن القيامُ بذلك بالتحرك في الاتجاه المعاكس بحيث نتّجه من طبقة المخرجات إلى طبقة المدخلات. وبمجرّد أن نعرف قيمة الخسارة، يمكننا تحديث قيم الأوزان والانحياز للخلايا العصبية في طبقة المخرجات؛ بعد تحديث قيم الخلايا العصبية في طبقة المخرجات، يمكننا تحديث قيم الأوزان والانحياز للخلايا العصبية في الطبقة التي قبلها؛ أي الطبقة المخفية الأخيرة. بعد الانتهاء من ذلك، يمكننا تحديث قيم الأوزان والانحياز في الطبقة التي قبلها؛ أي الطبقة المخفية قبل الأخيرة. وهكذا إلى أن نصل إلى طبقة المدخلات.

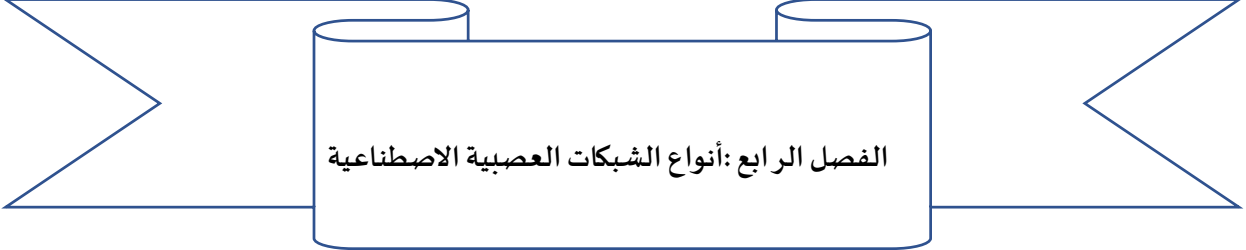


طريقة تحديث قيم الأوزان والانحياز للخلايا العصبية ماثلة لطريقة تحديثها في الخلية العصبية المفردة. مرة أخرى، تُحسب التحديثات بناءً على المشتقات الرياضية. يمكن تخيل شبكة عصبية كاملة كدالة كبيرة تتألف متغيراتها من قيم الأوزان والانحياز لكل الخلايا العصبية. بعد ذلك، يمكن حساب مشتقة كل وزن وانحياز فيما يتعلق بالخسارة، واستخدام تلك المشتقة لتحديث الخلية العصبية. وبذلك نصل إلى صميم عملية التعلّم في الشبكات العصبية ألا وهو "خوارزمية الانتشار العكسي".

بالنسبة إلى كل مُدخل والمُخرج المطلوب:

- تُحسب المخرجات والخسارة في الشبكة العصبية المتقدمة طبقةً تلو الأخرى بحيث نتقدّم إلى الأمام من طبقة المدخلات إلى طبقة المخرجات.
- تُحدّث قيم الأوزان والانحياز لتقليل الخسارة، بحيث نسير بترتيب عكسي من طبقة المخرجات إلى طبقة المدخلات.

باستخدام خوارزمية الانتشار العكسي، يمكننا بناء شبكات عصبية معقّدة وتدريبها على تنفيذ مهامّ مختلفة. فأنظمة التعلم العميق البسيطة عبارة عن خلايا عصبية اصطناعية بقدرات حسابية محدودة؛ إذ تأخذ المدخلات وتضربها في الأوزان وتجمعها ثم تضيف قيمة الانحياز ثم تطبّق إحدى دوال التنشيط على القيمة الناتجة. بينما تستمد هذه الخلايا للشبكات المعقدة قوّتها من الربط بين الكثير والكثير منها بطرق خاصة، حيث يمكن تدريب الشبكات الناتجة لتنفيذ المهمة التي نريد منها تنفيذها.

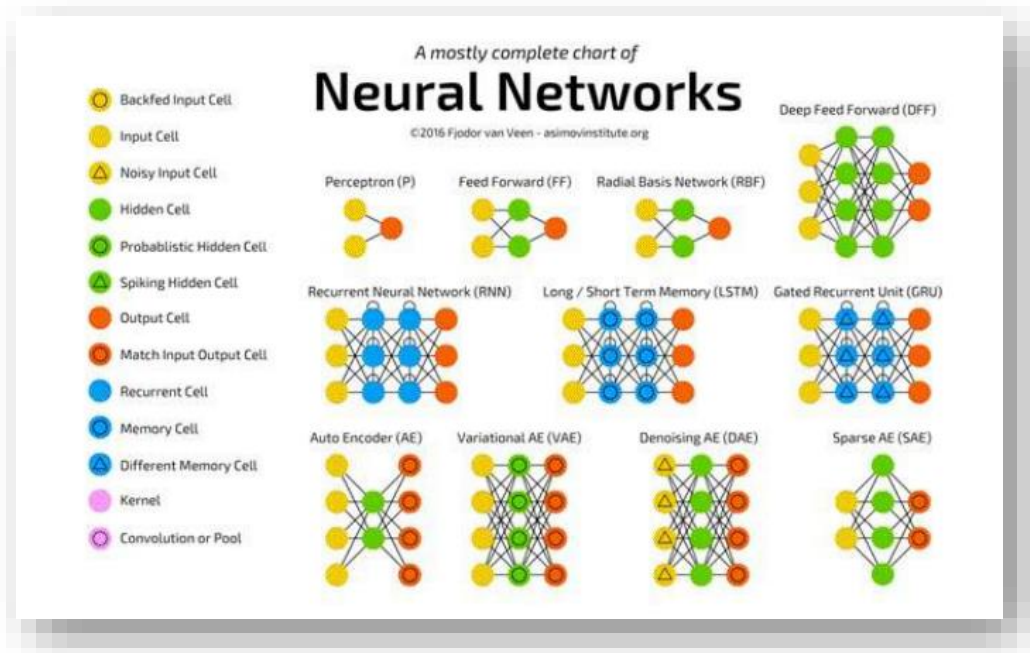


الفصل الرابع: أنواع الشبكات العصبية الاصطناعية

مقدمة:

هناك العديد من أنواع الشبكات العصبية التي تستخدم في التعلم العميق يمكن ذكر أشهرها على النحو التالي:

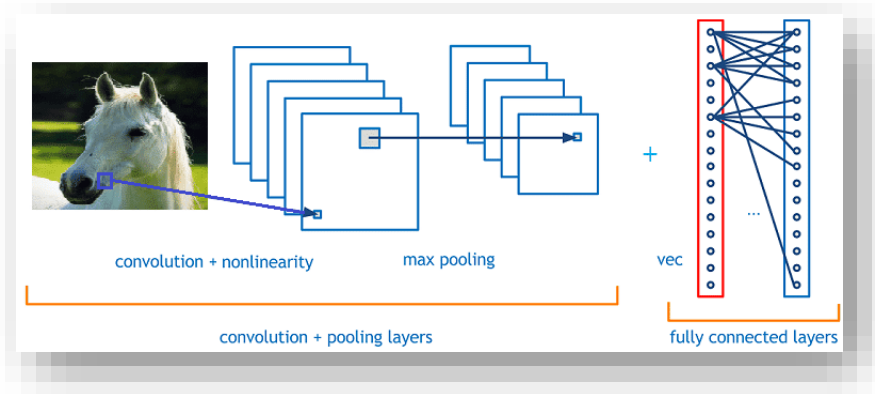
- الشبكات العصبية التلافيفية (CNNs)
- الشبكات العصبية المتكررة (RNNs)
- شبكات الذاكرة طويلة المدى (LSTMs)
- شبكات الخصومة التوليدية (GANs)
- شبكات وظيفة الأساس الشعاعي (RBFNs)
- بيرسيبترون متعدد الطبقات (MLPs)
- خرائط التنظيم الذاتي (SOMs)
- شبكات المعتقدات العميقة (DBNs)
- آلات Boltzmann المقيدة (RBMs)
- أجهزة التشفير التلقائي (Autoencoders)
- شبكات هوبفيلد العصبية (HNN) Hopfield Neural Networks
- شبكات Q العميقة (DQN)
- الشبكات العصبية المغذية (FNNs)



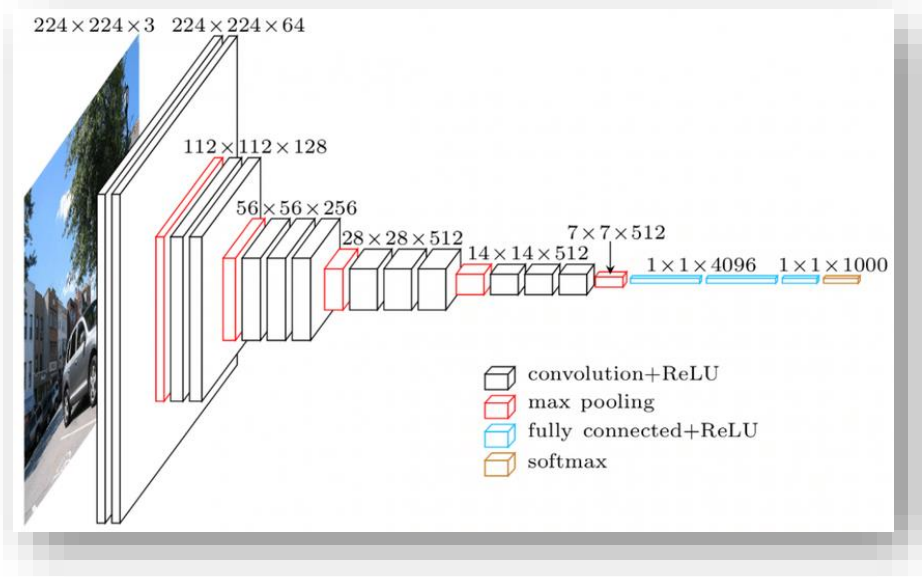
1- الشبكات العصبية التلافيفية (CNNs)

CNN عبارة عن شبكة عصبية متعددة الطبقات ذات بنية فريدة مصممة خصيصًا لاستخراج ميزات البيانات المعقدة بشكل متزايد في كل طبقة وتعد شبكات CNN مناسبة تمامًا للمهام الإدراكية. تعرف باسم ConvNets، طورها يان لتكون أول شبكة CNN في عام 1988 وأطلق عليها اسم LeNet. وكان الغرض الأساسي منها استخدامها للتعرف على الأحرف مثل الرموز البريدية والأرقام. وتتكون من طبقات متعددة وتستخدم هذه الخوارزمية وظيفتها لتسمى الالتواء المفهوم الكامن وراءها هو أنه بدلاً من ربط كل خلية عصبية بجميع الخلايا التي تليها، فإننا نربطها بحفنة منها فقط (المجال الاستقبالي).

بطريقة ما، يحاولون تنظيم شبكات التغذية الأمامية لتجنب التجهيز الزائد (عندما يتعلم النموذج فقط البيانات التي تم عرضها مسبقًا ولا يمكنه التعميم)، مما يجعلها جيدة جدًا في تحديد العلاقات المكانية بين البيانات.



تتكون الصور من وحدات البكسل التي تحدد شدة البياض في الصورة. كل بكسل من الصورة هو ميزة سيتم تغذيتها للشبكة العصبية. على سبيل المثال، تشير الصورة بمقاس 128×128 إلى أن الصورة مكونة من 16384 بكسل أو ميزات. سيتم تغذيته كمتجه بحجم 16384 للشبكة العصبية. بالنسبة للصور الملونة، هناك 3 قنوات (واحدة لكل منها - الأحمر والأزرق والأخضر). في هذه الحالة، نفس الصورة الملونة ستكون بحجم $3 \times 128 \times 128$ بكسل.



هناك تسلسل هرمي في طبقات CNN تحاول الطبقة الأولى استخراج الميزات الأولية للصور مثل الحواف الأفقية أو الرأسية. تستخرج الطبقات الثانية المزيد من الرؤى من الميزات التي تستخرجها الطبقة الأولى. ستتعمق الطبقات التالية بعد ذلك بشكل أعمق في التفاصيل لتحديد أجزاء معينة من الصورة مثل الشعر والجلد والأنف وما إلى ذلك. وأخيرًا، ستصنف الطبقة الأخيرة الصورة المدخلة على أنها صورة إنسان أو قطة أو كلب وما إلى ذلك.

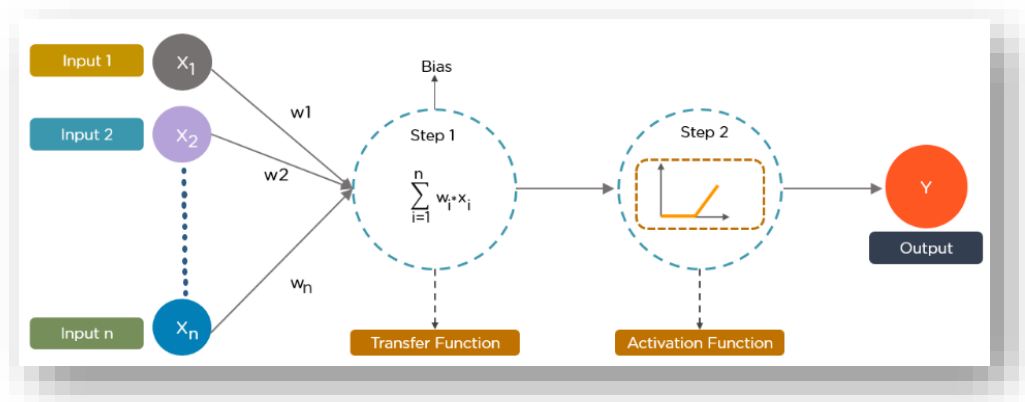
أهم استخداماتها:

تستخدم بشكل أساسي لمعالجة الصور واكتشاف الأشياء. وتستخدم شبكات CNN على نطاق واسع لتحديد صور الأقمار الصناعية ومعالجة الصور الطبية وتوقع السلاسل الزمنية واكتشاف الحالات الشاذة والسيارات ذاتية القيادة.

كيف تعمل شبكات CNN ؟

تحتوي شبكات CNN على طبقات متعددة تقوم بتجهيز واستخراج الخصائص من البيانات:

- طبقة الالتفاف: (CNN convolutional layer) تحتوي هذه الطبقة على عدة مرشحات لأداء عملية الالتفاف.
- الوحدة الخطية المصححة (ReLU): لدى CNN طبقة ReLU لإجراء عمليات على العناصر. الناتج هو خريطة معالم مصححة.
- طبقة التجميع (pooling layer): تغذي خريطة المعالم المصححة بعد ذلك طبقة التجميع. التجميع هو عملية أخذ عينات لأسفل تعمل على تقليل أبعاد خريطة المعالم. تقوم طبقة التجميع بعد ذلك بتحويل المصفوفات ثنائية الأبعاد الناتجة من خريطة المعالم المجمعة إلى متجه خطي واحد طويل ومستمر عن طريق تسويته.
- طبقة متصلة بالكامل (fully connected layer): تتشكل طبقة متصلة بالكامل عندما يتم تغذية المصفوفة المسطحة من طبقة التجميع كمدخلات، والتي تصنف الصور وتحددها.

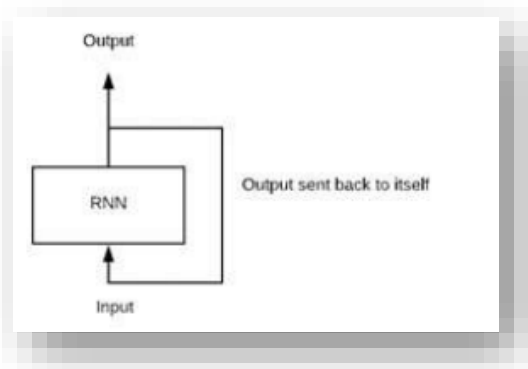


2- الشبكات العصبية المتكررة (RNNs)

تم تصميم الشبكات العصبية المتكررة للتعامل مع البيانات المتسلسلة. والبيانات المتسلسلة تعني البيانات التي لها بعض الارتباط مع البيانات السابقة مثل النص تسلسل الكلمات والجمل وما إلى ذلك أو مقاطع الفيديو تسلسل الصور والكلام وما إلى ذلك. من المهم جدًا فهم العلاقة بين هذه الكيانات المتسلسلة، وإلا فلن يكون من المنطقي خلط الفقرة بأكملها ومحاولة استخلاص بعض المعنى منها.


تم تصميم شبكات RNN لمعالجة هذه الكيانات المتسلسلة. من الأمثلة الجيدة على استخدام شبكات RNN هو الإنشاء التلقائي للترجمات في YouTube. إنه ليس سوى التعرف التلقائي على الكلام الذي يتم تنفيذه باستخدام RNNs. يتمثل الاختلاف الرئيسي بين الشبكات العصبية العادية والشبكات العصبية المتكررة في أن بيانات الإدخال تتدفق عبر بعدين الوقت (على طول التسلسل لاستخراج الميزات منه) والعمق (الطبقات العصبية العادية).

RNN عبارة عن شبكة عصبية متعددة الطبقات يمكنها تخزين المعلومات في سياق العقد، مما يسمح لها بتعلم تسلسل البيانات وإخراج رقم أو آخر، إنها شبكات عصبية اصطناعية لها اتصالات بين الخلايا العصبية تشمل الحلقات. تعتبر RNNs مناسبة تمامًا لمعالجة التسلسلات من المدخلات.



هناك أنواع مختلفة من شبكات RNN :

متعدد إلى واحد - RNN: في هذه البنية، يكون الإدخال الذي يتم تغذيته للشبكة عبارة عن تسلسل ويكون الإخراج كياناً واحداً. تُستخدم هذه البنية في معالجة مشكلات مثل تصنيف المشاعر أو للتنبؤ بدرجة المشاعر لبيانات الإدخال (مشكلة الانحدار). ويمكن استخدامه أيضاً لتصنيف مقاطع الفيديو إلى فئات معينة.
كثير إلى كثير - RNN: يعتبر كل من المدخلات والمخرجات تسلسلات في هذه البنية.
ويمكن تصنيفها أيضاً على أساس طول المدخلات والمخرجات على النحو التالي:
نفس الطول: - تنتج الشبكة مخرجات في كل خطوة زمنية. هناك مراسلات فردية بين المدخلات والمخرجات في كل خطوة زمنية. يمكن استخدام هذه البنية كجزء من أداة تمييز الكلام حيث يتم وضع علامة على كل كلمة من التسلسل في الإدخال مع جزء الكلام الخاص بها كإخراج في كل خطوة زمنية.
طول مختلف: - في هذه الحالة فإن طول المدخلات لا يساوي طول المخرجات. أحد استخدامات هذه البنية هو ترجمة اللغة. يمكن أن يختلف طول الجملة بالغة الإنجليزية عن الجملة الهندية المقابلة.
واحد إلى العديد - : الإدخال هنا هو كيان واحد بينما الإخراج عبارة عن تسلسل. تُستخدم هذه الأنواع من الشبكات العصبية لمهام مثل توليد الموسيقى والصور وما إلى ذلك.
واحد إلى واحد (One to One RNN): هي شبكة عصبية تقليدية يكون فيها الإدخال والإخراج كيانات فردية.

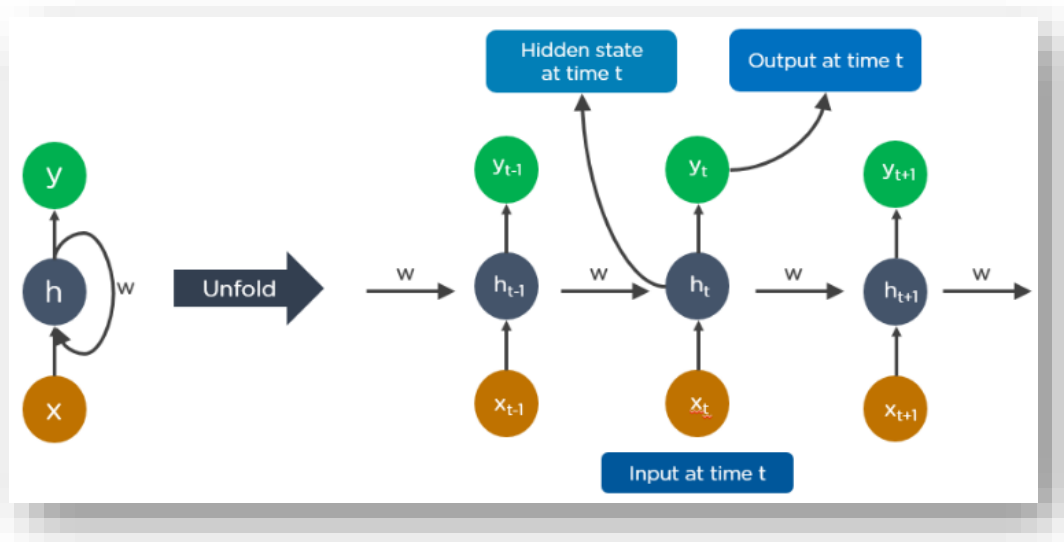


تحتوي RNN على اتصالات تشكل دورات موجهة، والتي تسمح بتغذية المخرجات من LSTM كمدخلات إلى المرحلة الحالية. يصبح الإخراج من LSTM مدخلاً إلى المرحلة الحالية ويمكنه حفظ المدخلات السابقة بسبب ذاكرته الداخلية.

ويمكن تبسيط الفهم بأنها عبارة عن حلقة من الإخراج إلى الإدخال لتميرير المعلومات مرة أخرى إلى الشبكة. ولذلك، فهي قادرة على تذكر البيانات السابقة واستخدام تلك المعلومات في التنبؤ بها.

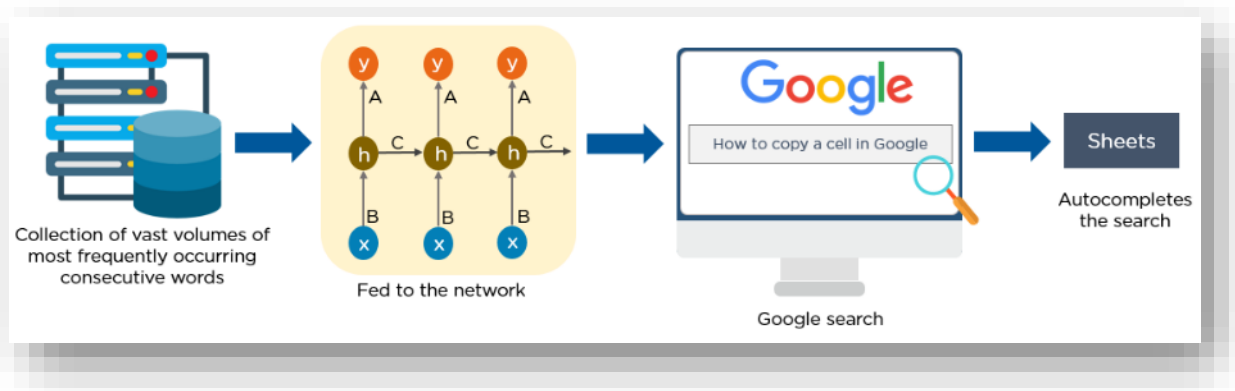
استخداماتها:

تعد الشبكات المتكررة مثالية للبيانات المرتبطة بالوقت ويتم استخدامها في تحليل السلاسل الزمنية وتستخدم RNNs بشكل شائع أيضاً لتسميات الصور، ومعالجة اللغة الطبيعية، والتعرف على خط اليد، والترجمة الآلية. تبعدو RNN غير المطوية كما يلي:



كيف تعمل RNNs؟

- الإخراج في الوقت $t-1$ يغذي المدخلات في الوقت t . وبالمثل، فإن المخرج في الوقت t يغذي المدخل في الوقت $t+1$.
 - يمكن لـ RNNs معالجة المدخلات بأي طول.
 - حسابات الحساب للمعلومات التاريخية، وحجم النموذج لا يزيد مع حجم الإدخال.
- فيما يلي مثال على كيفية عمل خاصية الإكمال التلقائي من Google:



3- شبكات الذاكرة طويلة المدى (LSTMs)

أحد عيوب الشبكات العصبية المتكررة هو اختفاء مشكلة التدرج. تتم مواجهة هذه المشكلة عندما نقوم بتدريب الشبكات العصبية باستخدام أساليب التعلم القائمة على التدرج مثل نزول التدرج العشوائي والانتشار العكسي. تدرجات وظيفة التنشيط هي المسؤولة عن تحديث أوزان الشبكات.

تصبح صغيرة جدًا بحيث لا تؤثر على تغيير أوزان الشبكات العصبية. وهذا يمنع الشبكات العصبية من التدريب. تواجه شبكات RNN هذه المشكلة عندما تواجه صعوبات في تعلم التبعية طويلة المدى.

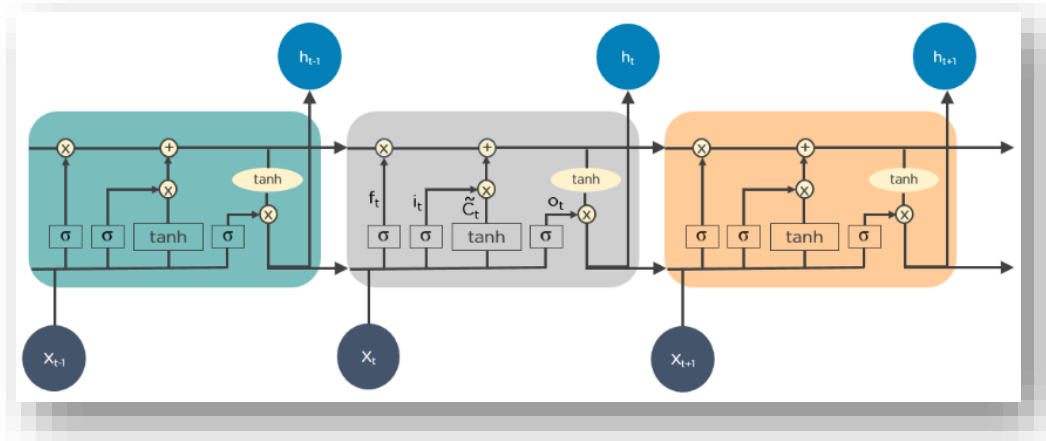
تم تصميم شبكات الذاكرة طويلة وقصيرة المدى (LSTM) لمواجهة هذه المشكلة بالذات. يتكون LSTM من وحدة ذاكرة يمكنها تخزين المعلومات ذات الصلة بالمعلومات السابقة. تعد الوحدات المتكررة المسورة (GRUs) أيضًا نوعًا مختلفًا من شبكات RNN التي تساعد في اختفاء مشاكل التدرج.

كلاهما يستخدم آلية النابضة لحل هذه المشكلة. تستخدم GRU معلمات تدريب أقل وبالتالي تستخدم ذاكرة أقل من LSTM. وهذا يمكن وحدات GRU من التدريب بشكل أسرع ولكن LSTM توفر نتائج أكثر دقة عندما تكون تسلسلات الإدخال طويلة.

LSTMs هي نوع من الشبكات العصبية المتكررة (RNN) التي يمكنها تعلم وحفظ التبعية طويلة المدى. حيث يتم استدعاء المعلومات السابقة لفترات طويلة كسلوك الافتراضي. تحتفظ LSTMs بالمعلومات بمرور الوقت.

أهم استخداماتها

تعتبر هذه الخوارزمية مفيدة في تنبؤ السلاسل الزمنية (time-series prediction) لأنها تتذكر المدخلات السابقة. تمتلك LSTMs بنية تشبه السلسلة حيث تتواصل أربع طبقات متفاعلة بطريقة فريدة. إلى جانب تنبؤات السلاسل الزمنية، وتستخدم LSTM عادةً للتعرف على الكلام وتكوين الموسيقى.



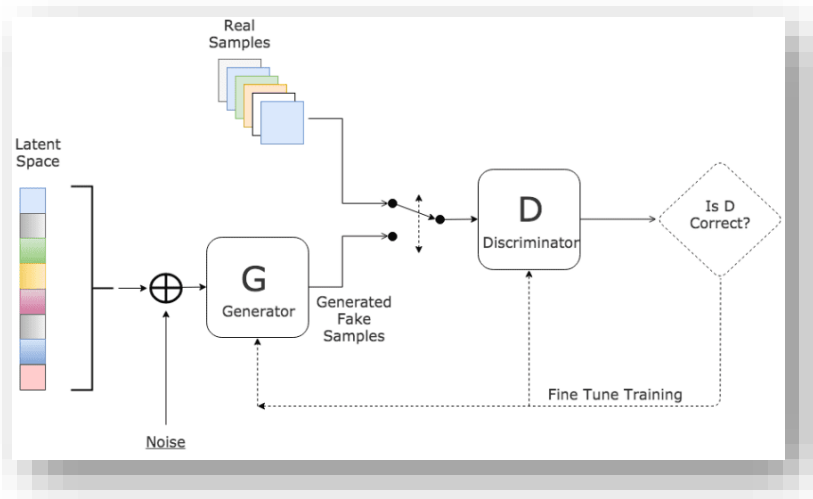
4- شبكات الخصومة التوليدية (GANs) Generative Adversarial Network

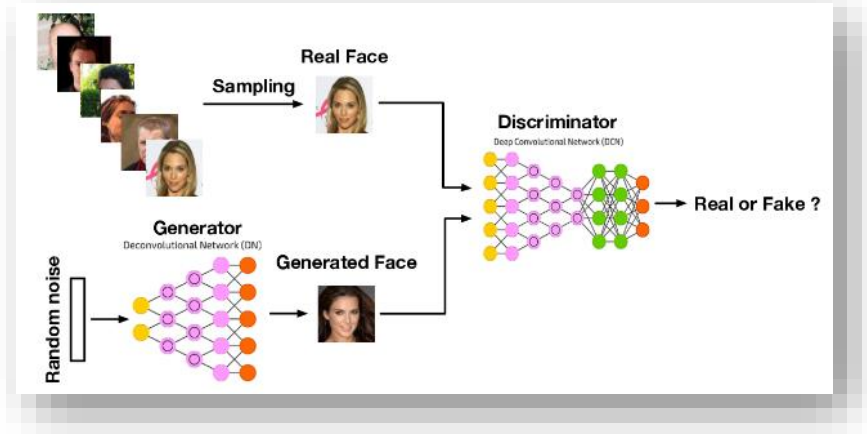
صممت شبكات GAN في عام 2016 بواسطة إيان جودفيلو، وهي تعتمد على فكرة بسيطة يمكن توضيحها على النحو التالي:

عند بناء نموذجين. نقوم بتدريب الأول على توليد بيانات مزيفة (المولد) والثاني على التمييز بين البيانات الحقيقية والمزيفة (التمييز). ونضعهم للتنافس ضد بعضهم البعض.

فشبكات GAN هي خوارزميات التعلم العميق التوليدية التي تنشئ حالات بيانات جديدة تشبه بيانات التدريب. يحتوي GAN على مكونين:

- مولد (generator) يتعلم إنشاء بيانات مزيفة.
- مميز (discriminator) يتعلم من تلك المعلومات الخاطئة.



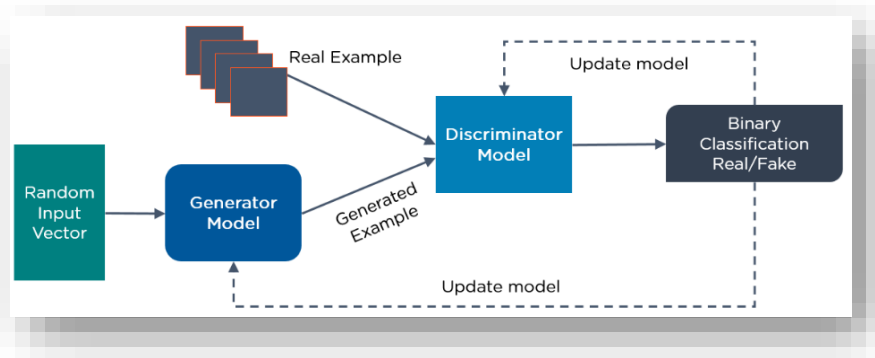


اهم استخداماتها:

- يمكن استخدامها لتحسين الصور الفلكية .
- يستخدمها مطورو ألعاب الفيديو لترقية التركيبات منخفضة الدقة وثنائية الأبعاد في ألعاب الفيديو القديمة عن طريق إعادة إنشائها بدقة 4 k أو دقة أعلى من خلال التدريب على الصور.
- تساعد شبكات GAN في إنشاء صور واقعية وشخصيات كرتونية.
- إنشاء صور فوتوغرافية لوجوه بشرية.
- تقديم كائنات ثلاثية الأبعاد.

طريقة عمل شبكات GAN :

- يتعلم المُمَيِّز (discriminator) التمييز بين البيانات المزيفة للمُنشئ وبيانات العينة الحقيقية. أثناء التدريب الأولي، يُنتج المولد بيانات مزيفة، وسرعان ما يتعلم المُمَيِّز أن يقول إنها خاطئة.
- يرسل GAN النتائج إلى المولد والمميز لتحديث النموذج.




5- شبكات وظيفة الأساس الشعاعي (RBFNs)

RBFNs هي أنواع خاصة من الشبكات العصبية المغذية التي تستخدم وظائف الأساس الشعاعي كدالة التفعيل. لديهم طبقة إدخال وطبقة مخفية وطبقة إخراج وتستخدم في الغالب للتصنيف والانحدار والتنبؤ بالسلاسل الزمنية.

كيف تعمل RBFNs ؟

- تقوم RBFNs بإجراء التصنيف عن طريق قياس تشابه المدخلات مع أمثلة من مجموعة التدريب.
- تمتلك RBFNs متجه إدخال يغذي طبقة الإدخال. لديها طبقة من الخلايا العصبية RBF.
- تبحث الدالة عن المجموع المرجح (weighted sum) للمدخلات، وتحتوي طبقة الإخراج على عقدة واحدة لكل فئة أو فئة من البيانات.
- تحتوي الخلايا العصبية في الطبقة المخفية على دالات النقل الغاوسي (Gaussian transfer) والتي لها نواتج تتناسب عكسياً مع المسافة من المركز.
- ناتج الشبكة عبارة عن مزيج خطي من دالات الأساس الشعاعي (radial-basis function) للإدخال ومعلمات الخلايا العصبية.




6- بيرسيبترون متعدد الطبقات (MLPs)

تنتمي MLP إلى فئة الشبكات العصبية الأمامية (feedforward neural networks) ذات الطبقات المتعددة من الإدراك الحسي التي لها وظائف التنشيط. تتكون MLP من طبقة إدخال وطبقة إخراج متصلة بالكامل. لديها نفس العدد من طبقات الإدخال والإخراج ولكن قد يكون لديها طبقات مخفية متعددة ويمكن استخدامها لبناء برامج التعرف على الكلام والتعرف على الصور والترجمة الآلية.

كيف تعمل MLP ؟

- تقوم MLP بتغذية البيانات إلى طبقة الإدخال الخاصة بالشبكة. تتصل طبقات الخلايا العصبية في رسم بياني بحيث تمر الإشارة في اتجاه واحد.
- تحسب MLP الإدخال بالأوزان الموجودة بين طبقة الإدخال والطبقات المخفية.
- تستخدم MLP دالات التفعيل لتحديد العقد التي يتم إطلاقها. تتضمن دالات التفعيل ReLUs والوظائف sigmoid و tanh.
- تقوم MLP بتدريب النموذج على فهم الارتباط ومعرفة التبعية بين المتغيرات المستقلة والمستهدفة من مجموعة بيانات التدريب.
- يوجد أدناه مثال على MLP يحسب الرسم البياني الأوزان والتحيز ويطبق دالات التفعيل المناسبة لتصنيف صور القطط والكلاب.



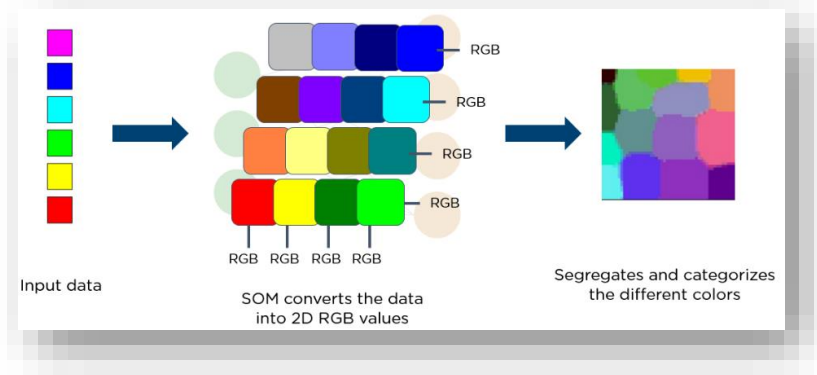
7- خرائط التنظيم الذاتي (SOMs)

اخترعها البروفيسور تيوفو كوهونين ، والتي تتيح تصور البيانات لتقليل أبعاد البيانات من خلال الشبكات العصبية الاصطناعية ذاتية التنظيم. يتم إنشاء SOMs لمساعدة المستخدمين على فهم هذه المعلومات عالية الأبعاد.

كيف تعمل SOM ؟

- تقوم SOMتهيئة الأوزان لكل عقدة واختيار متجه عشوائيًا من بيانات التدريب.
- تقوم SOM بفحص كل عقدة للعثور على الأوزان التي تكون على الأرجح متجه الإدخال. تسمى العقدة الفائزة أفضل وحدة مطابقة.(BMU).
- يكتشف SOM حي BMU، ويقل عدد الجيران بمرور الوقت.
- تمنح SOM وزنًا فائزًا لمتجه العينة. كلما اقتربت العقدة من BMU، كلما تغير وزنها.

- كلما كان الجار بعيداً عن BMU، قل ما يتعلمه. كرر SOM الخطوة الثانية للتكرار N. في الشكل التالي رسماً تخطيطياً لمتجه الإدخال بألوان مختلفة. يتم تغذية هذه البيانات إلى SOM، والتي تقوم بعد ذلك بتحويل البيانات إلى قيم ثنائية الأبعاد RGB. أخيراً، يفصل ويصنف الألوان المختلفة.

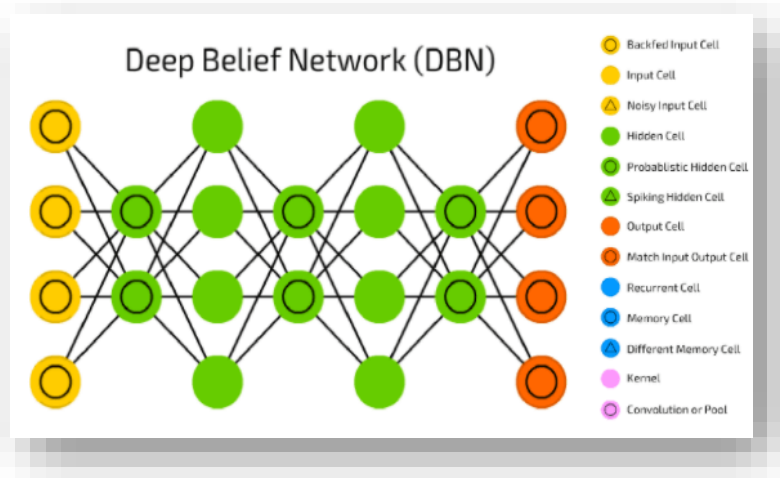



8- شبكات المعتقدات العميقة (DBNs)

DBNs هي نماذج توليدية (generative models) تتكون من طبقات متعددة من المتغيرات العشوائية والكامنة. المتغيرات الكامنة (latent variables) لها قيم ثنائية وتسمى غالباً الوحدات المخفية. DBNs عبارة عن كومة من آلات Boltzmann مع وصلات بين الطبقات، وتتواصل كل طبقة RBM مع كل من الطبقات السابقة واللاحقة. تُستخدم شبكات المعتقد العميق (DBNs) للتعرف على الصور والتعرف على الفيديو وبيانات التقاط الحركة.

كيف تعمل DBN؟

- خوارزميات (Greedy learning algorithms) تدرب DBN.
- تستخدم الخوارزمية نهج طبقة تلو الأخرى لتعلم الأوزان التوليدية التنازلية.
- تقوم DBN بتشغيل خطوات أخذ عينات جيبس على الطبقتين المخفيتين العلويتين.
- ترسم هذه المرحلة عينة من RBM التي تحددها الطبقتان المخفيتان العلويتان.
- سحب عينة DBN من الوحدات المرئية باستخدام ممر واحد لأخذ العينات من خلال بقية النموذج.
- تعلم DBN أنه يمكن الاستدلال على قيم المتغيرات الكامنة في كل طبقة من خلال تمرير واحد من أسفل إلى أعلى.



9- آلات Boltzmann المقيدة (RBMs)

طورها جيفري هينتون، RBMs هي شبكات عصبية عشوائية غير حتمية ذات قدرات توليدية وتتعلم توزيع الاحتمالات على المدخلات. وهي شكل مقيد من آلة بولتزمان، مقيدة من حيث الترابطات بين العقد في الطبقة. تتضمن هذه الطبقات طبقتين فقط، أي الطبقة المرئية والطبقة المخفية. لا توجد طبقة إخراج في RBM والطبقات متصلة بالكامل ببعضها البعض .

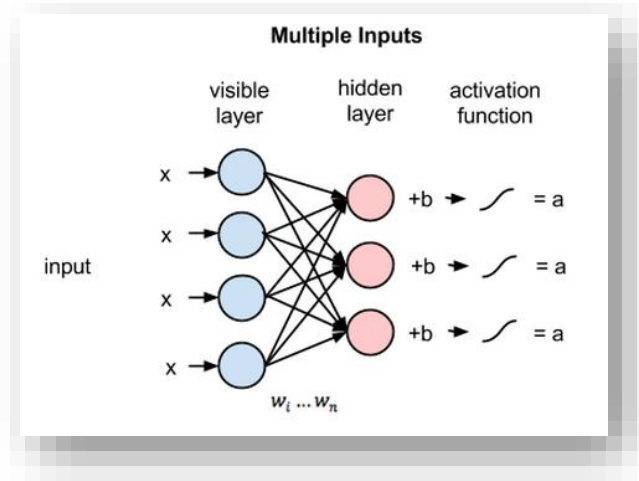
تُستخدم خوارزمية التعلم العميق هذه لتقليل الأبعاد والتصنيف والانحدار وتعلم الميزات ونمذجة الموضوع.

تشكل البلوك القائمة على النتائج اللبنات الأساسية لـ DBN

- الوحدات مرئية ((Visible units)
 - الوحدات المخفية ((Hidden units)
- كل وحدة مرئية متصلة بجميع الوحدات المخفية. تحتوي RBM على وحدة تحيز (bias) متصلة بجميع الوحدات المرئية والوحدات المخفية، ولا تحتوي على عقد إخراج.

كيف تعمل RBM ؟

- يتكون RBM من مرحلتين: التمرير الأمامي (forward pass) والتمرير الخلفي (backward pass).
- تقبل RBM المدخلات وترجمتها إلى مجموعة من الأرقام التي تشفر المدخلات في التمرير الأمامي.
- تجمع RBM بين كل مدخلات ووزن فردي وتحيز شامل واحد.
- تقوم الخوارزمية بتمرير الإخراج إلى الطبقة المخفية.
- في التمرير الخلفي، تأخذ RBM تلك المجموعة من الأرقام وترجمتها لتشكيل المدخلات المعاد بناؤها.
- تجمع RBM كل دالة تفعيل مع الوزن الفردي والتحيز الكلي وتمرير الإخراج إلى الطبقة المرئية لإعادة البناء.
- في الطبقة المرئية، يقارن RBM إعادة الإعمار مع المدخلات الأصلية لتحليل جودة النتيجة.



10- أجهزة التشفير التلقائي (Autoencoders)

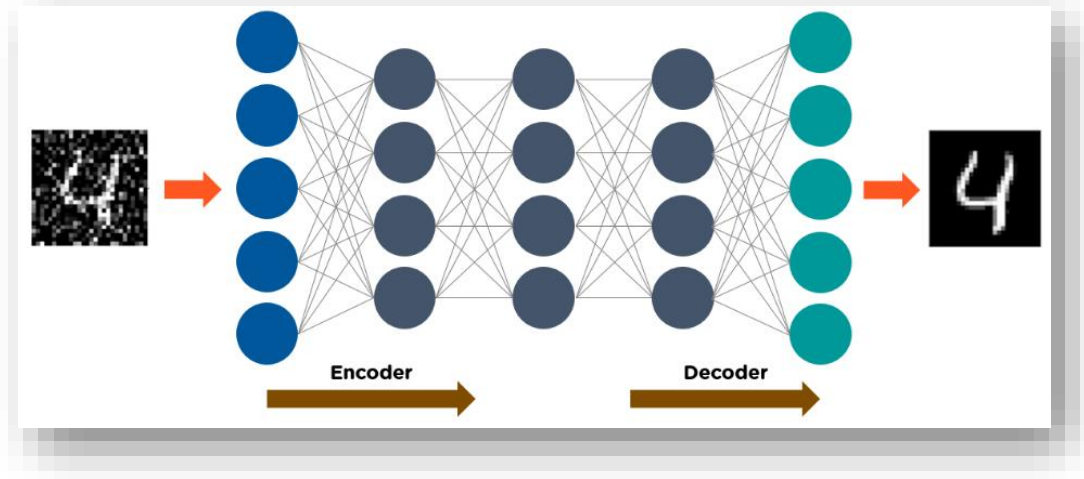
تعد أجهزة التشفير التلقائي (Autoencoders) نوعًا محددًا من الشبكة العصبية الأمامية (feedforward neural network) التي يكون فيها المدخلات والمخرجات متطابقة. صمم جيفري هينتون أجهزة التشفير التلقائي في الثمانينيات لحل مشاكل التعلم دون الإشراف (unsupervised learning) وهي عبارة عن شبكات عصبية مدربة تقوم بتكرار البيانات من طبقة الإدخال إلى طبقة الإخراج. تُستخدم أجهزة التشفير التلقائية لأهداف معينة مثل اكتشاف المستحضرات الطبية وتوقع الشعبية ومعالجة الصور.

كيف تعمل أجهزة التشفير التلقائي (Autoencoders) ؟

يتكون جهاز التشفير التلقائي من ثلاثة مكونات رئيسية:


- المشفر (encoder).
- الرمز (code).
- وحدة فك التشفير (decoder).

- تم تصميم أجهزة التشفير التلقائي لتلقي المدخلات وتحويلها إلى تمثيل مختلف. ثم تحاول إعادة بناء المدخلات الأصلية بأكثر قدر ممكن من الدقة.
- عندما لا تكون صورة الرقم مرئية بوضوح ، فإنها تتغذى على شبكة عصبية للتشفير التلقائي.
- تقوم أجهزة التشفير التلقائي أولاً بترميز الصورة، ثم تقليل حجم الإدخال إلى تمثيل أصغر.
- أخيراً، يقوم برنامج التشفير التلقائي بفك تشفير الصورة لإنشاء الصورة المعاد بناؤها.



11- شبكات هوبفيلد العصبية Hopfield Neural Network


و تعتبر شبكة متصلة تمامًا حيث ترتبط كل خلية. تُستخدم شبكات هوبفيلد في مهام التحسين و مهام تخزين البيانات بالإضافة إلى ذلك ، يمكن أن تتعلم هذه الشبكات تخزين الأنماط و استردادها عند عصبية بكل خلية عصبية أخرى تقديمها بإصدارات جزئية أو متدهورة من النمط.



12- الشبكات العصبية المغذية (FNNs)

الشبكات العصبية المغذية (FNNs) هي نوع أساسي من الشبكات العصبية الاصطناعية حيث تتدفق المعلومات في اتجاه واحد، من طبقة الإدخال عبر الطبقات المخفية إلى طبقة الإخراج دون أي دورات. فهي متعددة الاستخدامات وقادرة على تقريب الوظائف المختلفة، وتستخدم بشكل شائع في حل مشكلات الانحدار والتصنيف في مهام التعلم الآلي والتعرف على الأنماط.

- الإيجابيات: بنية بسيطة، وأسهل في التدريب، ومناسبة للعديد من مهام التعلم الخاضعة للإشراف.
- السلبيات: قد يواجه صعوبة في التعامل مع البيانات التسلسلية أو الزمنية وقد يتطلب معالجة مسبقة كبيرة للبيانات.



13- شبكات Q العميقة (DQN)

Deep Q-Network (DQN) هي خوارزمية التعلم المعزز التي تجمع بين التعلم العميق و Q-Learning لحل مشكلات اتخاذ القرار المتسلسلة المعقدة. تم تقديم DQN بواسطة DeepMind في عام 2013 وحققت نجاحًا كبيرًا في مجالات مختلفة، بما في ذلك لعب ألعاب Atari والتحكم في الروبوتات وتحسين تخصيص الموارد. كيفية عمل DQN؟

Q-Learning تعتمد DQN على خوارزمية Q-Learning، وهي شكل من أشكال التعلم المعزز. يهدف Q-learning إلى تعلم السياسة المثلى للوكيل لتعظيم مكافأته التراكمية في بيئة معينة. ويحتفظ بجدول Q-value الذي يخزن المكافآت المتوقعة لكل زوج من إجراءات الحالة.

الشبكات العصبية العميقة: تستخدم DQN شبكات عصبية عميقة، وتحديدًا الشبكات العصبية التلافيفية العميقة (CNNs)، كمقربات للوظائف لتقدير قيم Q المدخلات إلى الشبكة هي الحالة الحالية، والمخرجات هي قيم Q المتوقعة لجميع الإجراءات الممكنة في تلك الحالة.

إعادة تشغيل التجربة: تستخدم DQN مخزنًا مؤقتًا لإعادة تشغيل التجربة، والذي يخزن تجارب الوكيل التي تتكون من الحالة والإجراء والمكافأة وانتقالات الحالة التالية. أثناء التدريب، يتم أخذ عينات من مجموعات صغيرة من الخبرات بشكل عشوائي من المخزن المؤقت لإعادة التشغيل لإلغاء ربط البيانات التسلسلية وتحسين استقرار التعلم.

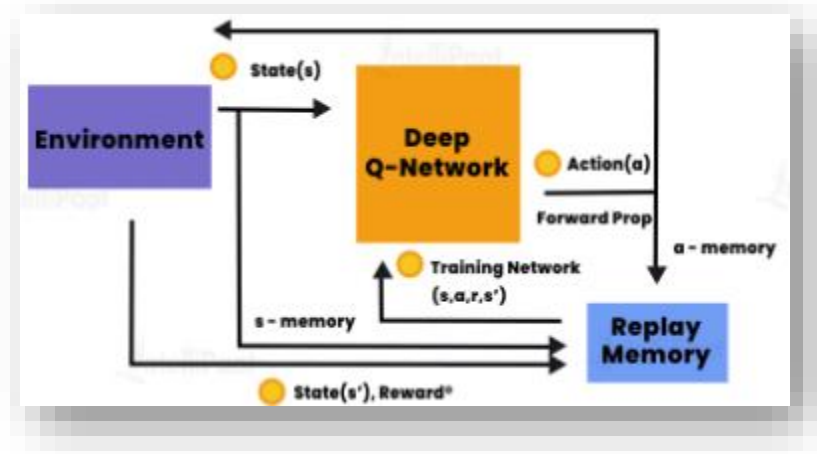
الشبكة المستهدفة: تستخدم DQN شبكة مستهدفة منفصلة وهي نسخة من الشبكة الرئيسية. يتم استخدام هذه الشبكة المستهدفة لحساب قيم Q المستهدفة أثناء التدريب، بينما يتم استخدام الشبكة الرئيسية للتنبؤ بقيم Q. يتم تحديث معلمات الشبكة المستهدفة بشكل دوري لتناسب مع معلمات الشبكة الرئيسية، مما يقلل من مشكلة الهدف المتحرك للقيمة المستهدفة.

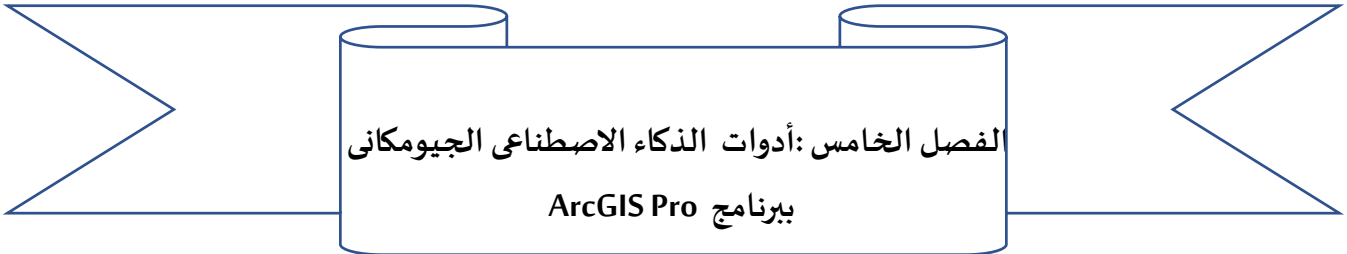
التدريب: تستخدم خوارزمية DQN دالة الخسارة التي تقلل الفرق بين قيم Q المتوقعة وقيم Q المستهدفة. يتم حساب الخسارة باستخدام متوسط الخطأ التربيعي (MSE) بين قيم Q المتوقعة وقيم Q المستهدفة. يتم تحديث معلمات الشبكة العصبية العميقة من خلال الانتشار العكسي لتقليل هذه الخسارة.

الاستكشاف مقابل الاستغلال: توازن DQN بين الاستكشاف والاستغلال باستخدام سياسة إبسيلون الجشعة. أثناء التدريب، يختار الوكيل الإجراءات ذات احتمالية الاستكشاف الأعلى (الإجراءات العشوائية) في البداية. مع تقدم التدريب، يقلل الوكيل تدريجيًا من الاستكشاف ويزيد من الاستغلال عن طريق اختيار الإجراءات بناءً على قيم Q المستفادة.

لقد أظهرت DQN قدرات مميزة، حيث تجاوزت أداء المستوى البشري في العديد من ألعاب Atari 2600 وحققت أحدث النتائج في العديد من مجالات التعلم المعزز. كما أنها مهدت الطريق للتقدم في التعلم المعزز العميق وتطوير خوارزميات أكثر تطورًا مثل Double DQN و Dueling DQN و Rainbow DQN.

ومع ذلك، لدى DQN بعض القيود، بما في ذلك إمكانية المبالغة في تقدير قيم Q والحساسية لاختيارات المعلمات الفائقة. اقترح الباحثون امتدادات وتحسينات مختلفة لمعالجة هذه القيود وتعزيز استقرار وأداء الخوارزمية. بشكل عام، تعد DQN خوارزمية بارزة للتعلم المعزز العميق أثبتت نجاحها في تعلم المهام المعقدة مباشرة من المدخلات الحسية الخام، مما يجعلها علامة بارزة في مجال الذكاء الاصطناعي والتعلم المعزز.





الفصل الخامس: أدوات الذكاء الاصطناعي الجيومكاني
برنامج ArcGIS Pro

مقدمة:


قامت Esri بتطوير أدوات وسير عمل للاستفادة من أحدث الابتكارات في التعلم العميق للإجابة على بعض الأسئلة الصعبة في تطبيقات نظم المعلومات الجغرافية والاستشعار عن بعد. تعد رؤية الكمبيوتر، أو قدرة أجهزة الكمبيوتر على اكتساب الفهم من الصور أو مقاطع الفيديو الرقمية، مجالاً يتحول من خوارزميات التعلم الآلي التقليدية إلى أساليب التعلم العميق. قبل تطبيق التعلم العميق على الصور في ArcGIS Pro، من المهم فهم التطبيقات المختلفة للتعلم العميق لرؤية الكمبيوتر.

تطبيقات التعلم العميق لرؤية الكمبيوتر:

هناك العديد من مهام رؤية الكمبيوتر التي يمكن إنجازها باستخدام الشبكات العصبية للتعلم العميق. قامت Esri بتطوير أدوات تسمح لك بإجراء تصنيف الصور واكتشاف الكائنات والتجزئة الدلالية وتجزئة المثيلات. يتم وصف جميع مهام رؤية الكمبيوتر هذه أدناه، مع كل منها مثال للاستشعار عن بعد ومثال أكثر عمومية لرؤية الكمبيوتر.

تصنيف الصور (Image classification):

يتضمن تصنيف الصور تعيين تسمية أو فئة لصورة رقمية. على سبيل المثال، قد تحمل صورة الطائرة بدون طيار الموجودة على اليسار أدناه اسم "حشد"، وقد تحمل الصورة الرقمية الموجودة على اليمين اسم "قطة". يُعرف هذا النوع من التصنيف أيضاً بتصنيف الكائنات أو التعرف على الصور، ويمكن استخدامه في نظم المعلومات الجغرافية لتصنيف الميزات في الصورة.



Object detection: (كشف الكائنات)


اكتشاف الكائنات هو عملية تحديد موقع الميزات في الصورة. على سبيل المثال، في صورة الاستشعار عن بعد أدناه، وجدت الشبكة العصبية موقع طائرة. في حالة استخدام الرؤية الحاسوبية الأكثر عمومية، قد يكون النموذج قادراً على اكتشاف موقع الحيوانات المختلفة. تتضمن هذه العملية عادةً رسم مربع محيط حول الميزات محل الاهتمام. ويمكن استخدامه في نظم

المعلومات الجغرافية لتحديد ميزات محددة في صور الأقمار الصناعية أو الجوية أو صور الطائرات بدون طيار ولرسم تلك الميزات على الخريطة.



Semantic segmentation:

التجزئة الدلالية يحدث التجزئة الدلالية عندما يتم تصنيف كل بكسل في الصورة على أنه ينتمي إلى فئة ما. على سبيل المثال، في الصورة الموجودة على اليسار أدناه، يتم تصنيف بكسلات الطريق بشكل منفصل عن بكسلات غير الطرق. على اليمين، يتم تصنيف وحدات البكسل التي تشكل قطة في الصورة على أنها قطة، بينما تنتمي وحدات البكسل الأخرى في الصورة إلى فئات أخرى. في نظم المعلومات الجغرافية، يُشار إلى ذلك غالبًا باسم تصنيف البكسل، أو تجزئة الصورة، أو تصنيف الصور. وغالبًا ما يتم استخدامه لإنشاء خرائط تصنيف استخدامات الأراضي.



: Instance segmentation

يعد تجزئة المثيلات طريقة أكثر دقة للكشف عن الكائنات حيث يتم رسم حدود كل مثيل للكائن. على سبيل المثال، في الصورة الموجودة على اليسار أدناه، يتم الكشف عن أسطح المنازل، بما في ذلك المخطط التفصيلي الدقيق لشكل السقف. على اليمين

يتم الكشف عن السيارات، ويمكنك رؤية الشكل المميز للسيارات. يُعرف هذا النوع من تطبيقات التعلم العميق أيضًا بتجزئة الكائنات.



:Panoptic segmentation

يجمع التجزئة البانوبتيكية بين التجزئة الدلالية وتجزئة المثيلات. على سبيل المثال، توضح الصورة أدناه أن جميع وحدات البكسل مصنفة، وكل كائن فريد، مثل كل سيارة، هو كائن فريد خاص به.



: Image translation

ترجمة الصور هي مهمة ترجمة صورة من تمثيل أو نمط محتمل للمشاهد إلى آخر، مثل تقليل الضوضاء أو الدقة الفائقة. على سبيل المثال، الصورة الموجودة على اليسار أدناه توضح الصورة الأصلية ذات الدقة المنخفضة، والصورة الموجودة على اليمين توضح نتيجة استخدام نموذج فائق الدقة. يُعرف هذا النوع من تطبيقات التعلم العميق أيضًا بالترجمة من صورة إلى صورة.



كشف التغيير Change detection :

يمكن لمهام التعلم العميق لاكتشاف التغيير اكتشاف التغييرات في الميزات محل الاهتمام بين تاريخين وإنشاء خريطة منطقية للتغيير. على سبيل المثال، الصورة على اليسار أدها توضح تطويرًا سكنيًا منذ خمس سنوات، والصورة الوسطى توضح نفس التطور اليوم، والصورة على اليمين توضح خريطة التغيير المنطقية حيث المنازل الجديدة باللون الأبيض.

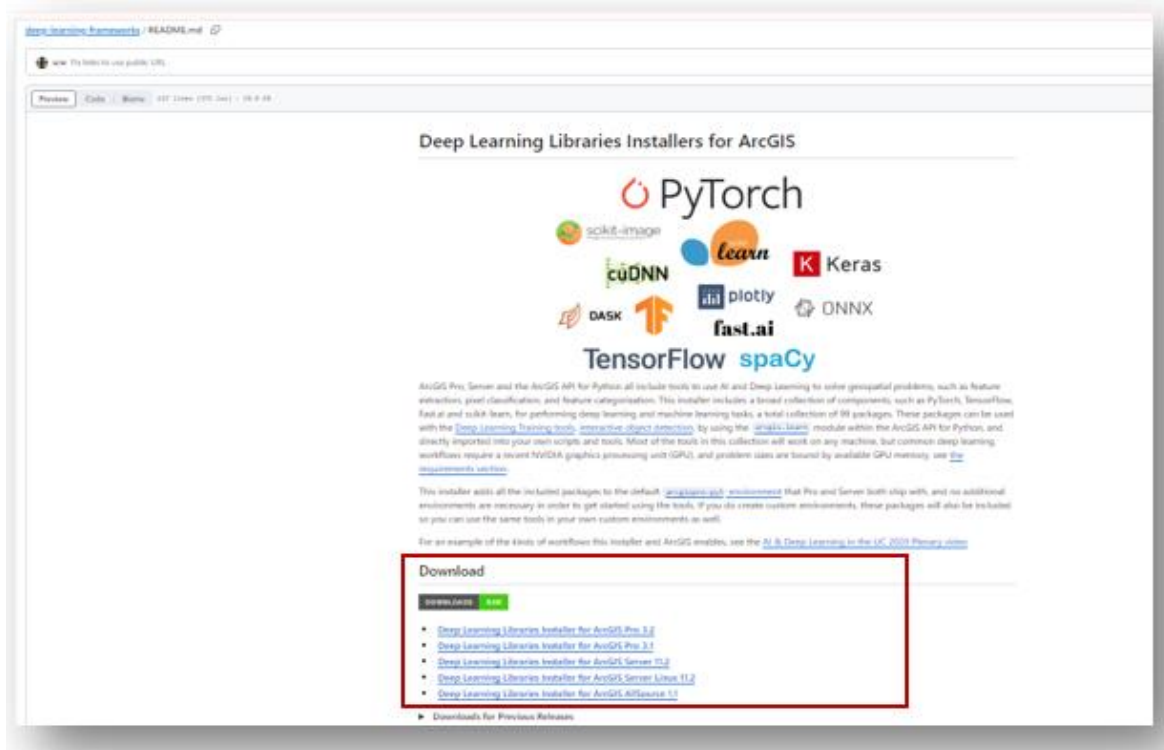


تجهيزات بيئة العمل:

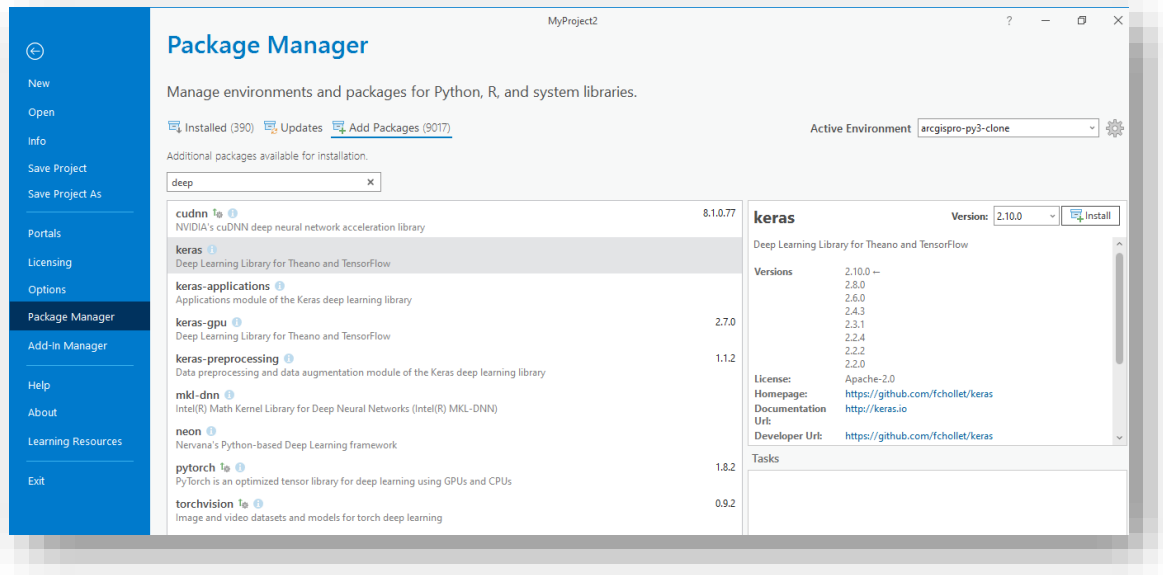
تحميل وتهيئة Deep Learning Data Frame

<https://github.com/Esri/deep-learning->

[frameworks/blob/master/README.md?rmedium=links_esri_com_b_d&source=https%3A%2F%2Flinks.esri.com%2Fdeep-learning-framework-install](https://github.com/Esri/deep-learning-)



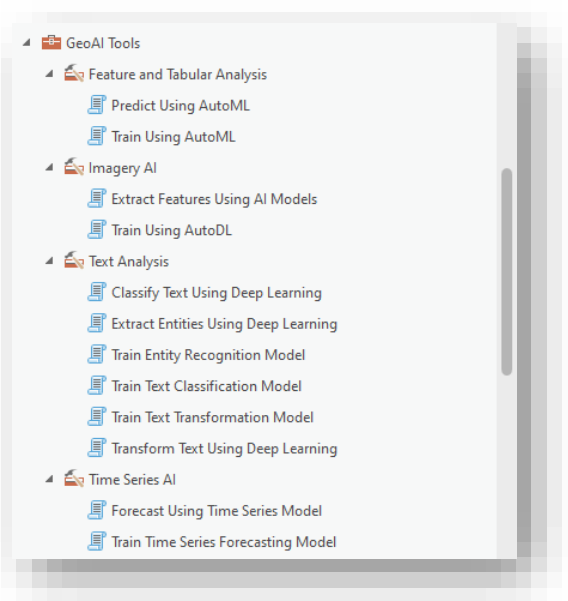
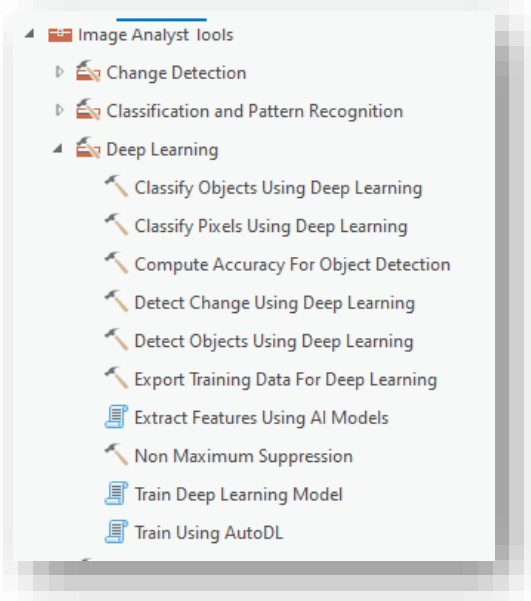
يتم اختيار Data Frame متوافقة مع نسخة البرنامج على جهازي : ثم عمل تحميل لها وبعد ذلك عمل تهيئة على الجهاز
تأكد من انها جاهزة للعمل داخل البرنامج



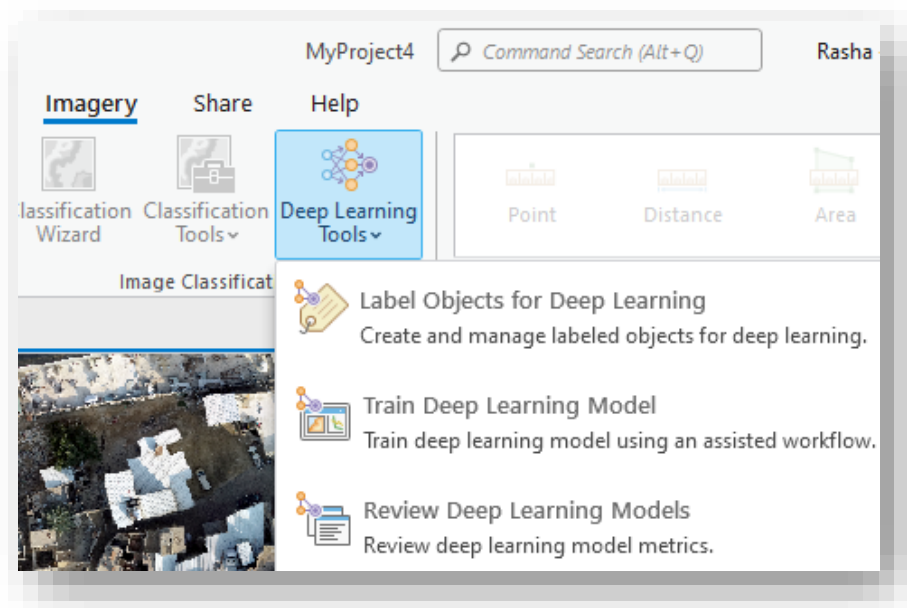
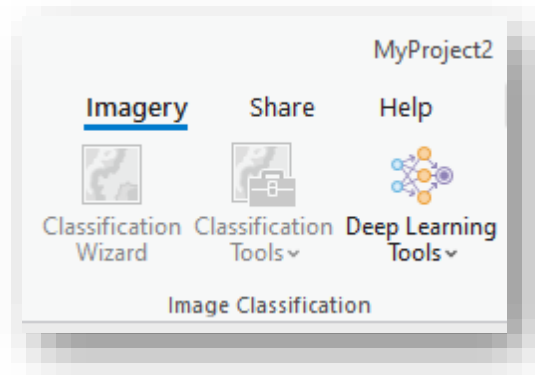
يتم تهيئة بيئة العمل بالبرنامج والتأكد من كارت الشاشة به من خلال اتباع الخطوات الموجودة بالرابط التالي :

<https://learn.arcgis.com/en/projects/get-ready-for-deep-learning-in-arcgis-pro/>

هناك مجموعة من ادوات الذكاء الاصطناعي الجيومكاني داخل برنامج ArcGISPro



بالإضافة إلى شريط أدوات داخل Imagery

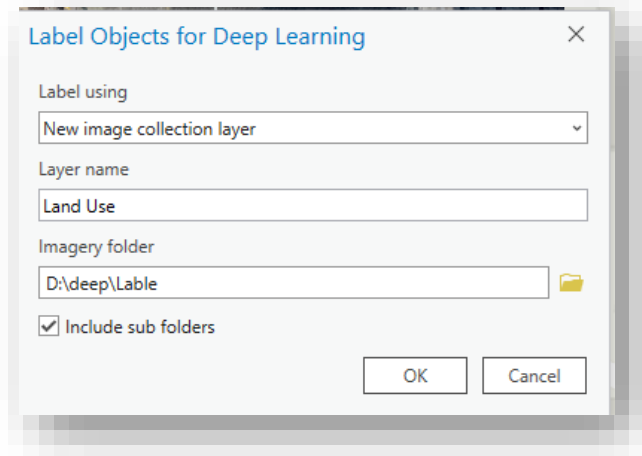


وفيما يلي شرح لاستخدامات هذا الشريط :

Label Object for Deep Learning: تستخدم لتسمية ال Features التي لم يكن لها مسميات واستخراج بيانات لتدريب

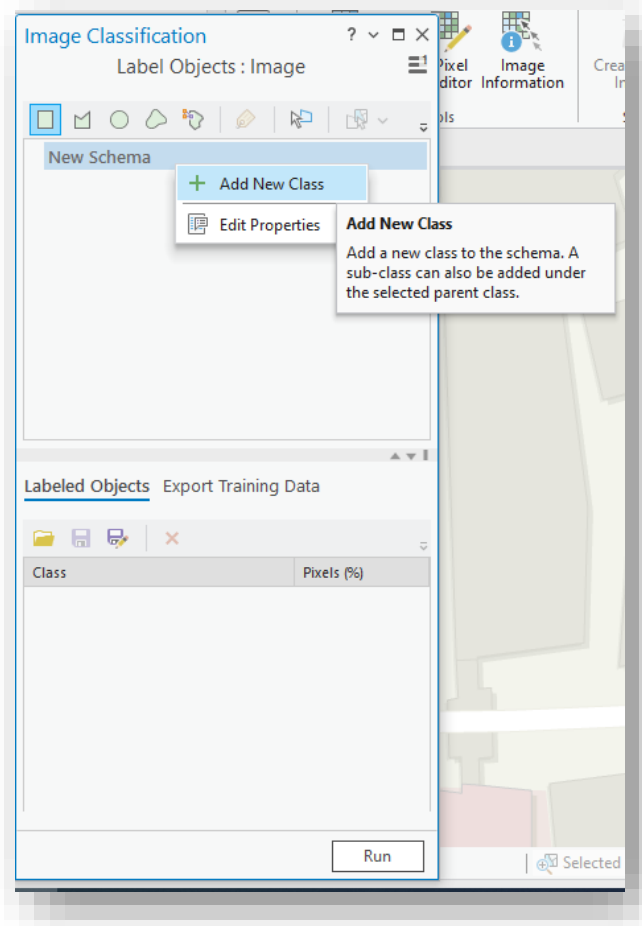
نموذج الذكاء الاصطناعي ؛ ويتم العمل بها على النحو التالي :

بمجرد اختيارها تظهر نافذة ؛ يتم اختيار New Image Collection Layer ؛ ثم نضيف اسم للطبقة ونحدد مكان الحفظ .



ثم OK. تظهر النافذة التالية ؛ يتم اضافة تصنيف جديد للمسميات عن طريق النقر بالماوس الزر الأيمن واختيار Add

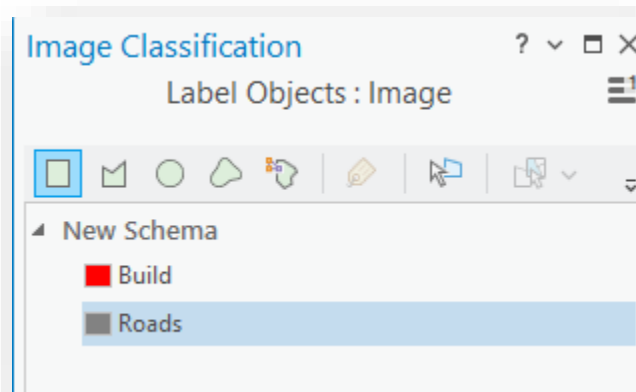
New Class



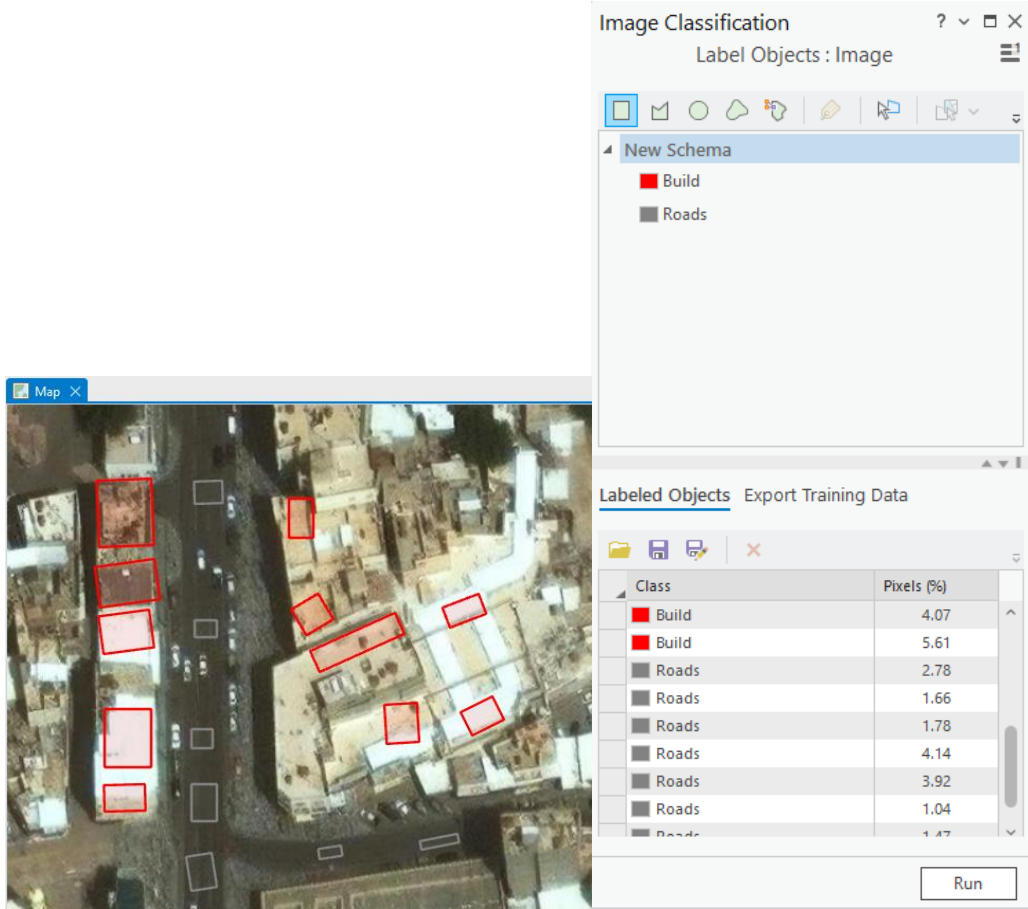
ثم يتم كتابة اسم ال class وتحديد اللون المطلوب يتم تكرار هذه العملية للمسميات المطلوبة
كما موضح أدناه

The screenshot shows the 'Image Classification' dialog box with the title 'Add New Class'. The 'Name' field contains 'Roads', the 'Value' field contains '2', and the 'Color' dropdown is set to a grey color. The 'Alias' field contains 'الطرق' and the 'Description' field is empty. 'OK' and 'Cancel' buttons are at the bottom.

The screenshot shows the 'Image Classification' dialog box with the title 'Add New Class'. The 'Name' field contains 'Build', the 'Value' field contains '1', and the 'Color' dropdown is set to a red color. The 'Alias' field contains 'المباني' and the 'Description' field is empty. 'OK' and 'Cancel' buttons are at the bottom.

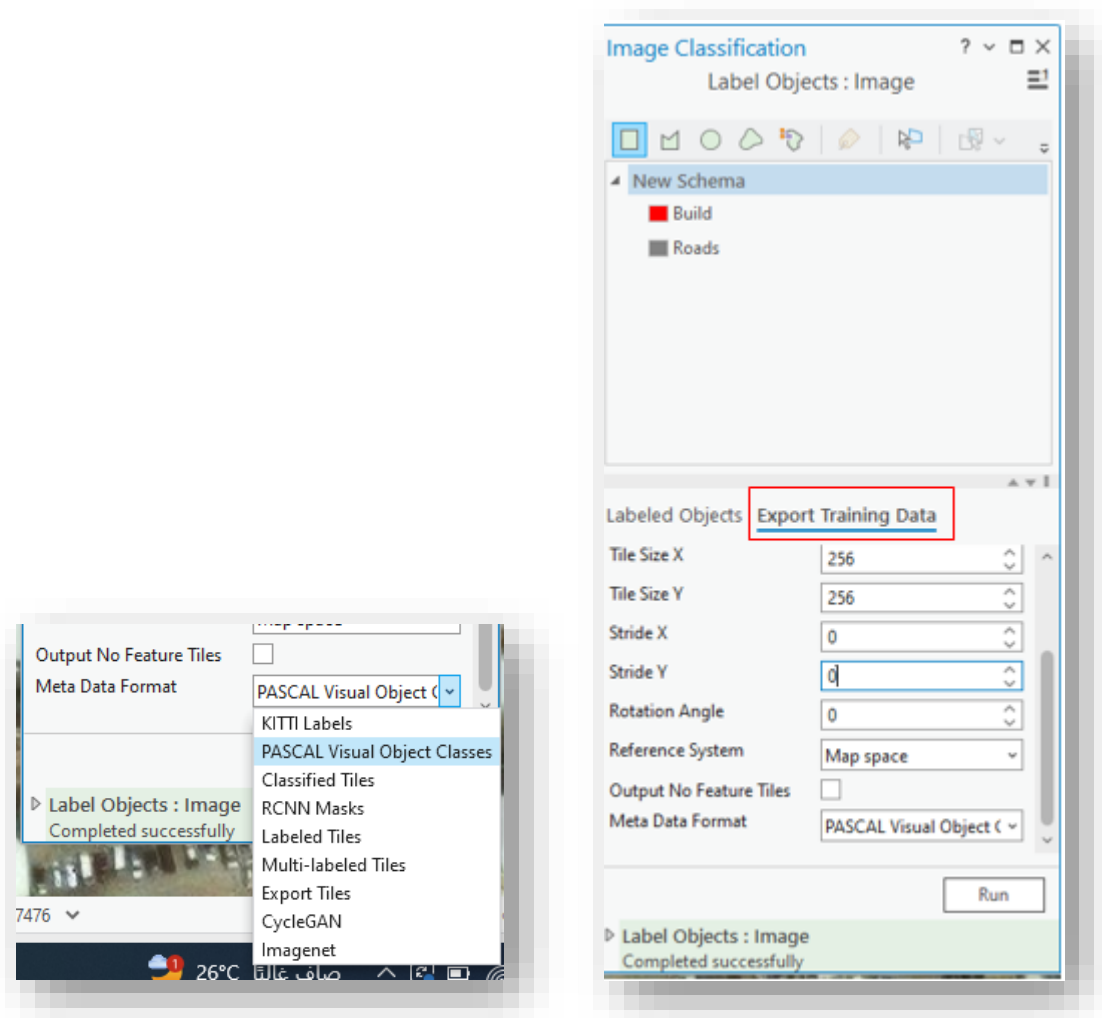


يتم أخذ عينات لكل منهما على النحو الموضح:

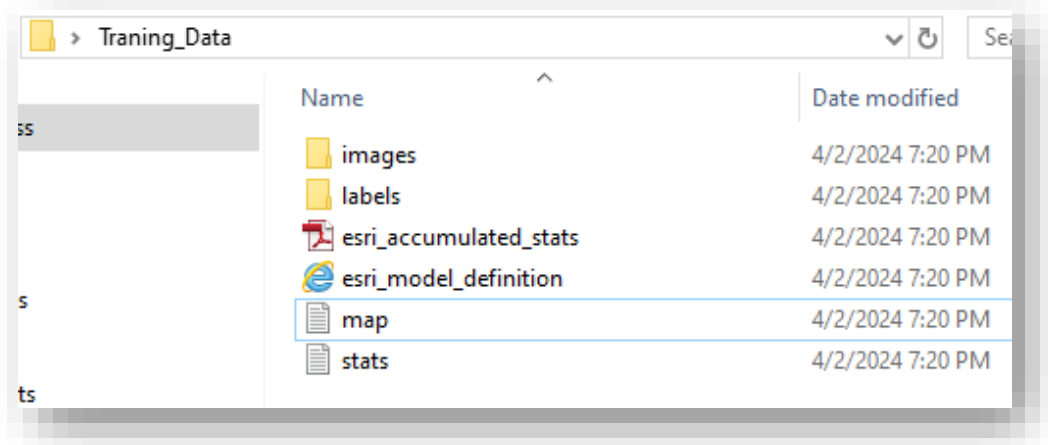


ثم اختيار Run.

من **Export Training Data** ؛ يتم تحديد مكان حفظ بيانات التدريب وعمل التعديلات اللازمة (حجم الصورة - نسبة التداخل المطلوبة " تم ضبطها على 0 أى لا اريد وجود تداخل " - اختيار النموذج المطلوب)

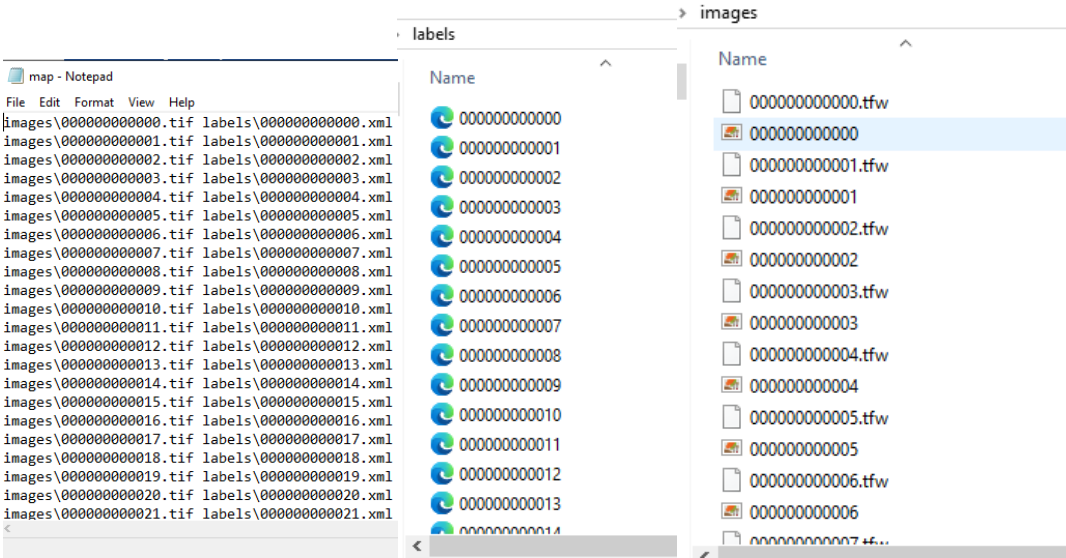


واخيرا Run. نجد الملفات موجودة داخل مجلد حفظ البيانات



وهي عبارة عن

ملف للصور عبارة عن العينات التدريبية وملف للمسميات وملف لل stats يوجد به احصائية بعدد العينات المأخوذة
وقيمة كل صنف " Class Value " (1 للمباني و 2 للطرق).



map - Notepad

```
File Edit Format View Help
images\00000000000.tif labels\00000000000.xml
images\00000000001.tif labels\00000000001.xml
images\00000000002.tif labels\00000000002.xml
images\00000000003.tif labels\00000000003.xml
images\00000000004.tif labels\00000000004.xml
images\00000000005.tif labels\00000000005.xml
images\00000000006.tif labels\00000000006.xml
images\00000000007.tif labels\00000000007.xml
images\00000000008.tif labels\00000000008.xml
images\00000000009.tif labels\00000000009.xml
images\00000000010.tif labels\00000000010.xml
images\00000000011.tif labels\00000000011.xml
images\00000000012.tif labels\00000000012.xml
images\00000000013.tif labels\00000000013.xml
images\00000000014.tif labels\00000000014.xml
images\00000000015.tif labels\00000000015.xml
images\00000000016.tif labels\00000000016.xml
images\00000000017.tif labels\00000000017.xml
images\00000000018.tif labels\00000000018.xml
images\00000000019.tif labels\00000000019.xml
images\00000000020.tif labels\00000000020.xml
images\00000000021.tif labels\00000000021.xml
```

stats - Notepad

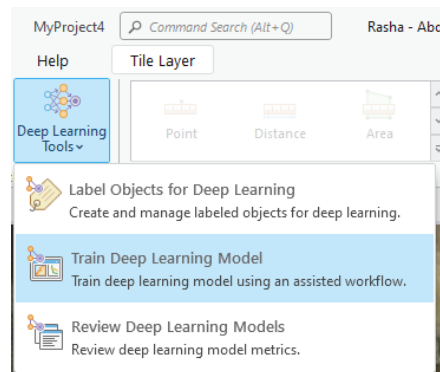
```
File Edit Format View Help
images = 238 *4*256*256

Class feature statistics:
features = 240
features per image = [min = 1, mean = 1.01, max = 2]
classes = 2
```

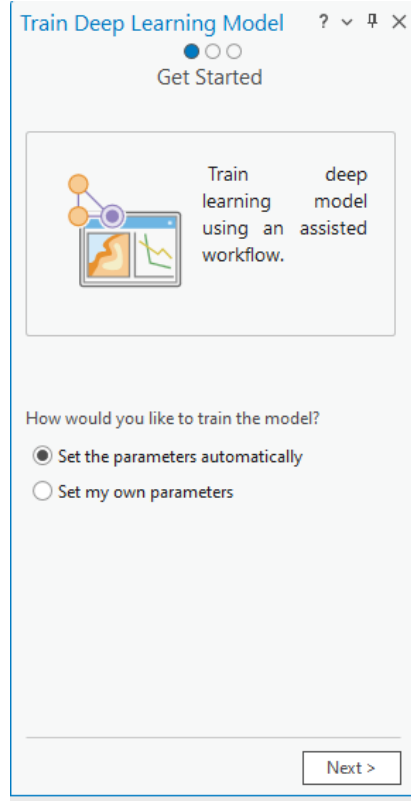
cls name	cls value	images	features	min size	mean size	max size
Build	1	180	182	0.01	3.49	5.56
Roads	2	58	58	0.01	2.77	5.56

Train Deep Learning Model : تستخدم لتدريب نموذج ذكاء اصطناعي من خلال البيانات التدريبية التي تم

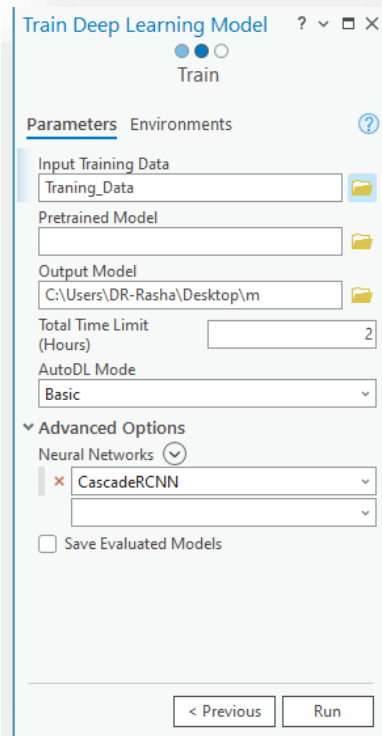
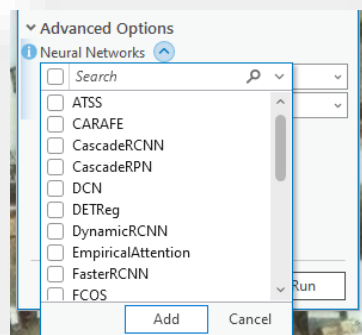
استخراجها من الاداة السابقة .



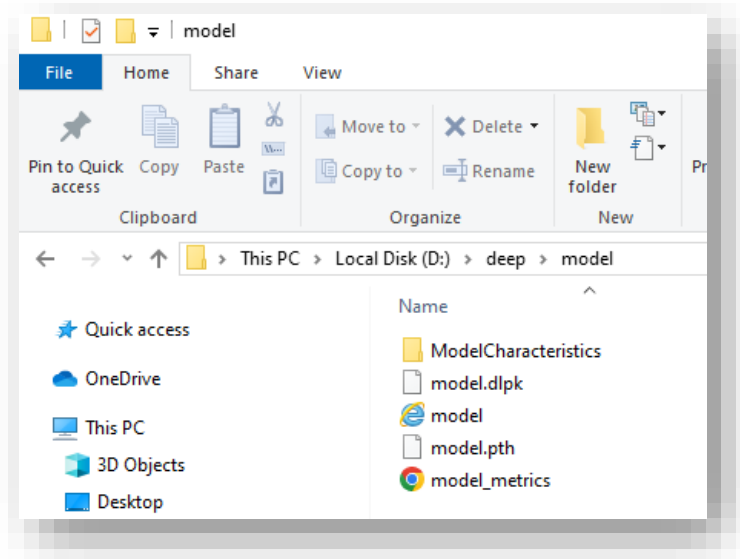
تظهر النافذة التالية



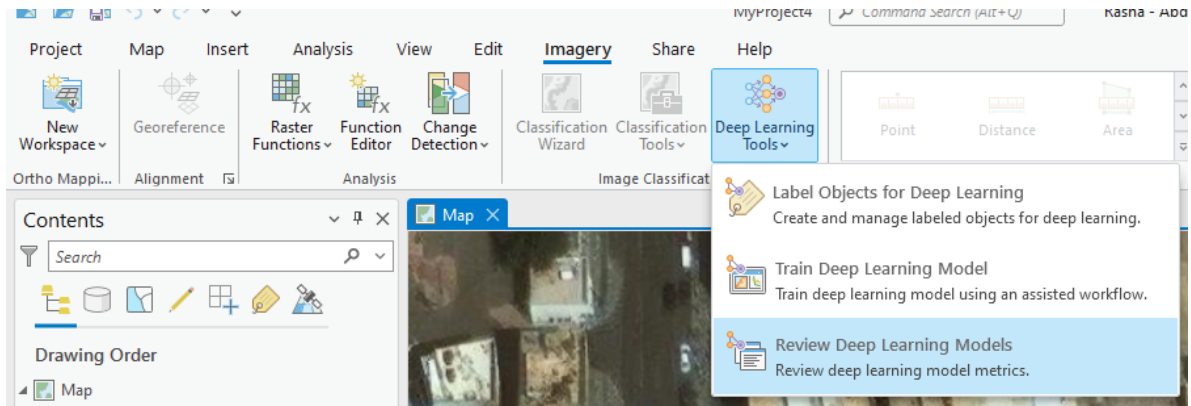
يتم اختيار Next يتم ادخال بيانات التدريب ومكان حفظ النموذج واختيار النموذج المطلوب تدريبه



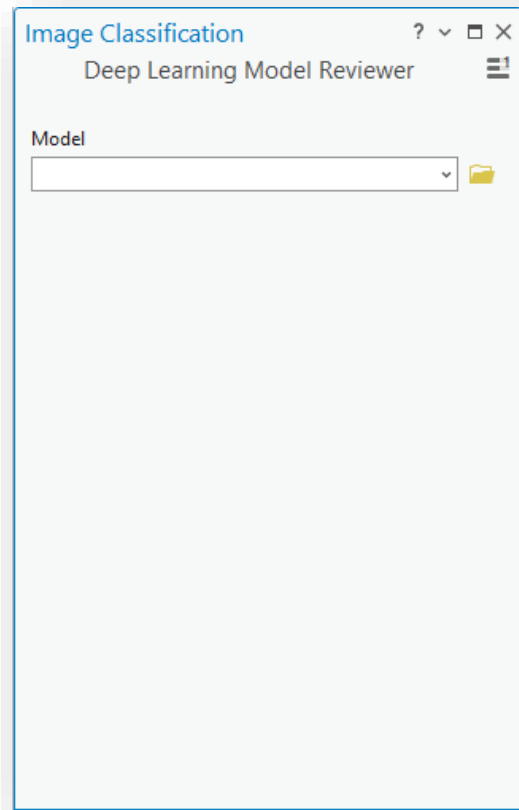
وأخيرا Run .



Review Deep Learning Model: تستخدم لمراجعة دقة نموذج التعلم العميق والذي تم تدريبه



فباختيار الاداة تظهر النافذة التالية



يتم اختيار النموذج المطلوب مراجعته ؛ فتظهر بيانات النموذج

النموذج المطلوب مراجعته والذي تم تدريبه مسبقا.

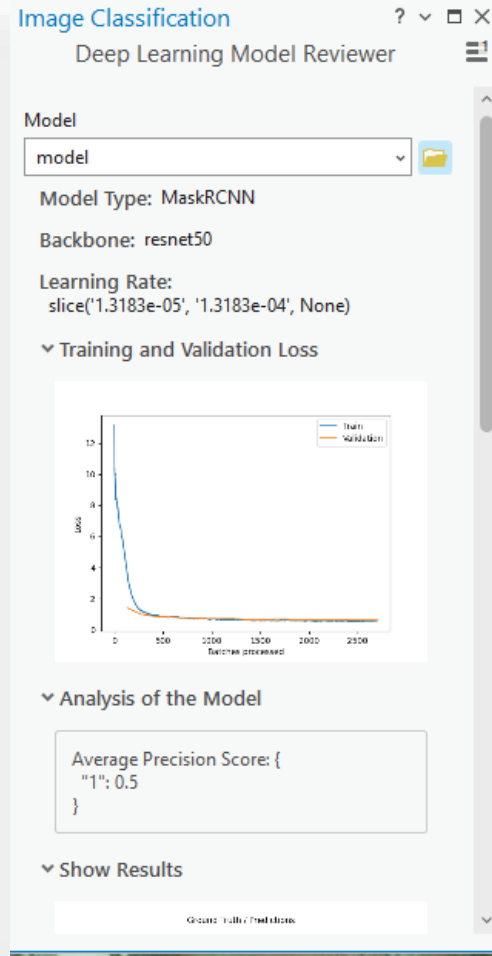
نوع النموذج وفي هذه الحالة RCNN.

اسم الشبكة العصبية التي تم تدريبها مسبقا.

معدل التعلم المستخدم في تدريب الشبكات العصبية. إذا لم تقم بتحديد القيمة، فسيتم حسابها بواسطة أداة التدريب.

يعرض القسم رسمًا بيانيًا يوضح فقدان التدريب وفقدان التحقق من الصحة على مدار تدريب النموذج.

تعرض المقاييس التالية لكل فئة: الدقة والاستدعاء ودرجة




Epochs Details

Epo	Train	Val	Tim	Other Metrics
15	0.5	0.6	00:01	"average_precision": 0.2
16	0.5	0.6	00:01	"average_precision": 0.2
17	0.5	0.6	00:01	"average_precision": 0.2
18	0.5	0.6	00:01	"average_precision": 0.2
19	0.5	0.6	00:01	"average_precision": 0.2
20	0.5	0.6	00:01	"average_precision": 0.2

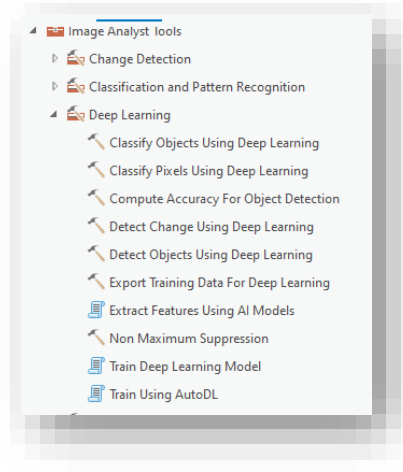
جدول يحتوي على معلومات لكل عصر، مثل فقدان التدريب، وفقدان التحقق من الصحة، والوقت، ومقاييس الأخرى

Show Results



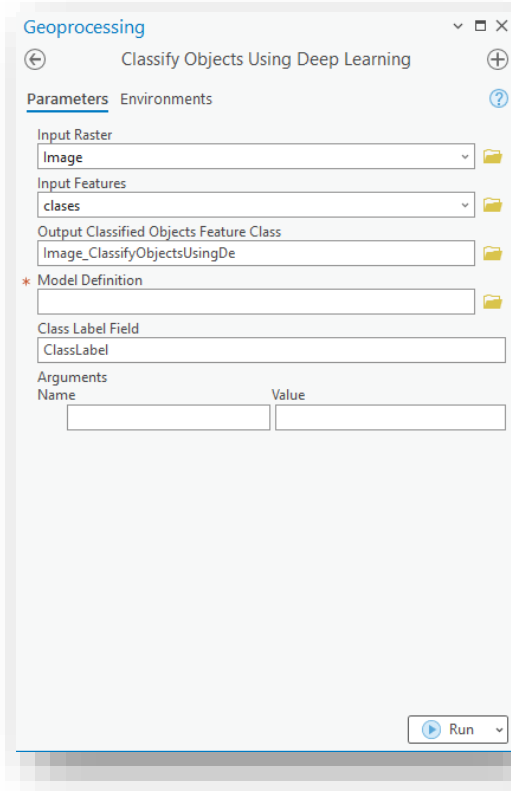
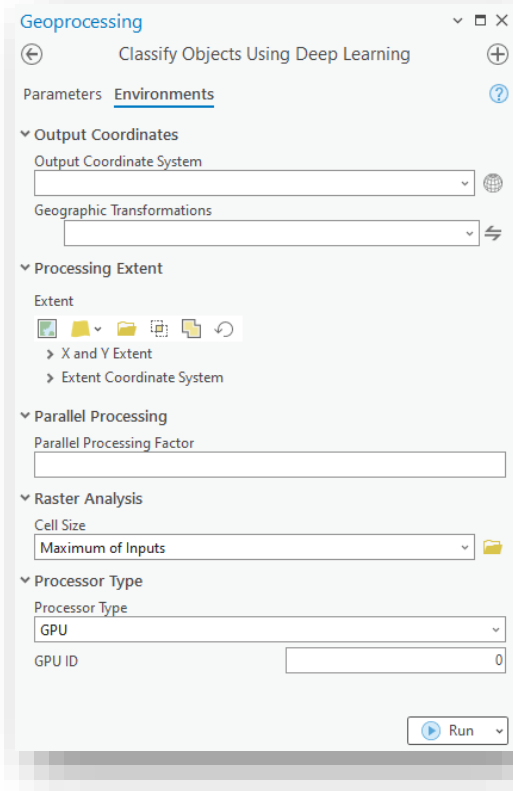
تعرض أمثلة على نتائج العينات

مجموعة أدوات Deep Learning





أداة Classify Object Using Deep Learning :

تستخدم هذه الأداة لعمل تصنيفات من صور جوية أو مرئيات فضائية مثل تصنيف الغطاء الأرضي حيث تعتمد الأداة على أخذ عينات من الظاهرات التي تحتاج إلى تصنيف (Object) وإعطاء اسم وقيمة لكل صنف تم أخذ عينات له تتطلب الأداة إدخال طبقة Raster والنموذج الذي سبق تدريبه ؛ ومن Enviroments يتم اختيار GPR



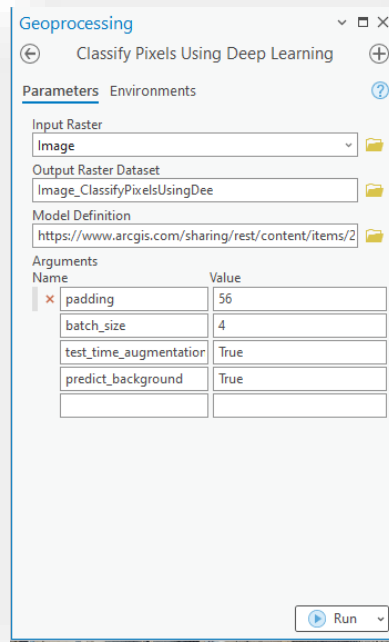
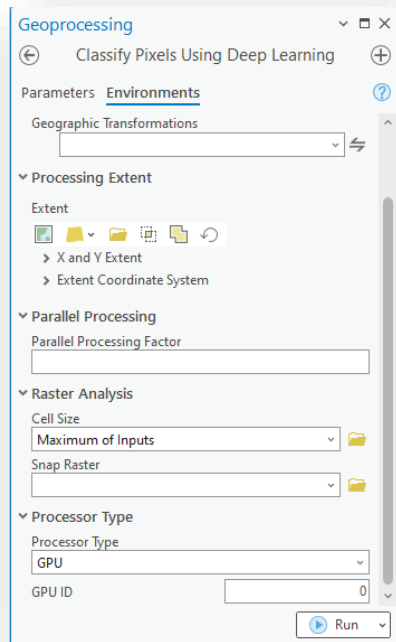
أداة Classify Pixel Using Deep Learning

الفرق بين Classify Pixels Using Deep Learning و Classify Object Using Deep Learning في Classify Object Using Deep Learning الكشف عن الكائنات : لدى صنف أو أكثر من صنف واريده رسم حدود على كل صنف على حدى بحيث يكون هذا الصنف هو المطلوب تحديده فمثلا لدى حيوانات (كلب وقطة) ومطلوب تصنيف هذه الكائنات لرسم مربع احمر حول فئة الكلب ومربع اصفر حول فئة القطة : بينما عند استخدام Classify Pixels Using Deep Learning فيكون التحليل أكثر دقة حيث يتم التصنيف بناء على البكسل (فجميع البكسل باللون الحمراء داخل فئة الكلب بينما البكسل ذات اللون الأصفر تنتمى الى القطة)



Classify Pixels Using Deep Learning

Classify Object Using Deep Learning



أداة Compute Accuracy For Object Detection

تستخدم هذه الاداة لحساب دقة نموذج التعلم العميق من خلال مقارنة الكائنات المكتشفة (الظواهرات التي تم استخراجها بالنموذج بأداة Detect Objects Using Deep Learning) بالبيانات الحقيقية الأساسية. والمخرج من هذه الأداة جدول يحتوي على معلومات تتعلق بدقة الإخراج ؛ يحتوي الجدول على مقاييس الدقة لكل فئة في البيانات المكتشفة، بالإضافة إلى صف لجميع الفئات (الدقة الإجمالية). يحتوي الجدول على الحقول التالية:

Precision: نسبة عدد النتائج الإيجابية الحقيقية إلى إجمالي عدد التنبؤات.

Recall: نسبة عدد الإيجابيات الحقيقية إلى العدد الإجمالي للتنبؤات الإيجابية.

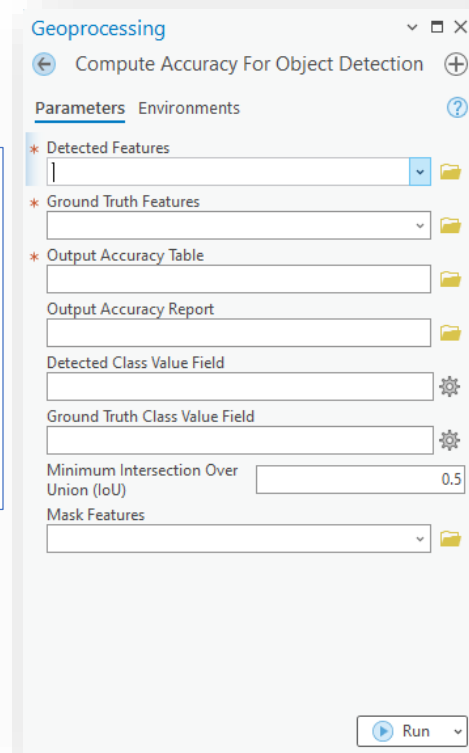
F1_Score: المتوسط المرجح للدقة والاستدعاء. تتراوح القيم من 0 إلى 1 حيث يعني 1 أعلى دقة.

AP—The Average Precision: وهو متوسط الدقة عبر جميع قيم الاستدعاء وتتراوح بين 0 و1

True_Positive: عدد النتائج الإيجابية الحقيقية التي تم إنشاؤها بواسطة النموذج.

False_Positive: عدد النتائج الإيجابية الخاطئة التي تم إنشاؤها بواسطة النموذج.

False_Negative: عدد النتائج السلبية الخاطئة التي تم إنشاؤها بواسطة النموذج.



- 1- الطبقة المخرجة من أداة Detect Objects Using Deep Learning
- 2- طبقة البيانات التي يتم المراجعة منها (بيانات الاختبار)
- 3- تحديد المكان الذي يحفظ فيه الجدول المخرج من الاداة
- 4- تحديد المكان الذي يحفظ فيه التقرير المخرج من لاداة
- 5- اختيار الحقل من الطبقة المراد مراجعتها
- 6- اختيار الحقل من الطبقة المرجعية

لفهم مخرجات أداة Compute Accuracy For Object Detection، يجب أولاً فهم نتائج نموذج الكشف عن الكائنات ؛ حيث أنه في اكتشاف الكائنات وتصنيفها، يمكن للنموذج التنبؤ بفئة إيجابية أو فئة سلبية، ويمكن أن تكون التنبؤات صحيحة أو خاطئة. على سبيل المثال، عند اكتشاف وجود أشجار في صورة ما، قد تكون الفئة الإيجابية "شجرة"، بينما ستكون الفئة السلبية "لا توجد شجرة". يحدث التنبؤ الحقيقي عندما يكون التنبؤ صحيحاً، ويحدث التنبؤ الخاطئ عندما يكون التنبؤ غير صحيح.

في الصورة أدناه، تشير المربعات المحيطة باللون الأحمر إلى توقع إيجابي، حيث تنبأ النموذج بوجود شجرة. تشير المربعات المحيطة باللون الأزرق الداكن إلى توقع سلبي، حيث توقع النموذج عدم وجود شجرة.




ف نجد أن هناك توقعات صحيحة واخرى خاطئة ويمكن توضيح الفرق بينهما وذلك على النحو التالي:

الوصف	القيمة
إيجابي حقيقي (تنبأ النموذج بوجود شجرة، وهذا صحيح).	1
إيجابية كاذبة (تنبأ النموذج بوجود شجرة، وهذا غير صحيح).	2
سلبي كاذب (توقع النموذج عدم وجود شجرة، وهذا غير صحيح).	3
صحيح سلبي (توقع النموذج عدم وجود شجرة، وهذا صحيح).	4

تعتمد دقة النموذج على جودة عينات التدريب وعددها، والصور المدخلة، ومعلومات النموذج، والحد الأدنى المطلوب للدقة.

يتم استخدام نسبة التقاطع على الاتحاد (IoU) كعتبة لتحديد ما إذا كانت النتيجة المتوقعة إيجابية حقيقية أم إيجابية كاذبة. نسبة IoU هي مقدار التداخل بين المربع المحيط حول كائن متوقع والمربع المحيط حول البيانات المرجعية.



الوصف	القيمة
المنطقة المتقاطعة للمربع المحيط المتوقع والمربع المحيط المرجعي الأرضي	1
المساحة الإجمالية للمربع المحيط المتوقع والمربع المحيط المرجعي الأرضي مجتمعين	2

يحتوي جدول دقة الإخراج وتقرير الدقة الذي تم إنشاؤه بواسطة أداة Compute Accuracy For Object Detection على مجموعة من مقاييس الدقة التي تعتمد على حد IoU وأداء النموذج. ويمكن تبسيط هذه المؤشرات على النحو التالي:

Precision الدقة: الدقة هي نسبة عدد النتائج الإيجابية الحقيقية إلى إجمالي عدد التنبؤات الإيجابية. على سبيل المثال، إذا اكتشف النموذج 100 شجرة، وكانت 90 منها صحيحة، فستكون الدقة 90 بالمائة.

$$\text{الدقة} = \frac{(\text{إيجابي حقيقي})}{(\text{إيجابي حقيقي} + \text{إيجابي كاذب})}$$


Recall والاستدعاء: هو نسبة عدد العناصر الإيجابية الحقيقية إلى العدد الإجمالي للكائنات الفعلية (ذات الصلة). على سبيل المثال، إذا اكتشف النموذج بشكل صحيح 75 شجرة في صورة ما، وكان هناك بالفعل 100 شجرة في الصورة، فإن نسبة الاستدعاء تبلغ 75 بالمائة.

$$\text{الاستدعاء} = \frac{(\text{إيجابي حقيقي})}{(\text{إيجابي حقيقي} + \text{سلي كاذب})}$$

F1 score: هي متوسط مرجح للدقة والاستدعاء. تتراوح القيم من 0 إلى 1، حيث يعني 1 أعلى دقة.

$$F1 \text{ score} = \frac{2 \times (\text{الدقة} \times \text{الاستدعاء})}{(\text{الدقة} + \text{الاستدعاء})}$$

منحنى استدعاء الدقة : هذا مخطط للدقة (المحور ص) والاستدعاء (المحور السيني)، ويعمل بمثابة تقييم لأداء النموذج. يعتبر النموذج نموذجًا تنبؤيًا جيدًا إذا ظلت الدقة عالية مع زيادة الاستدعاء.

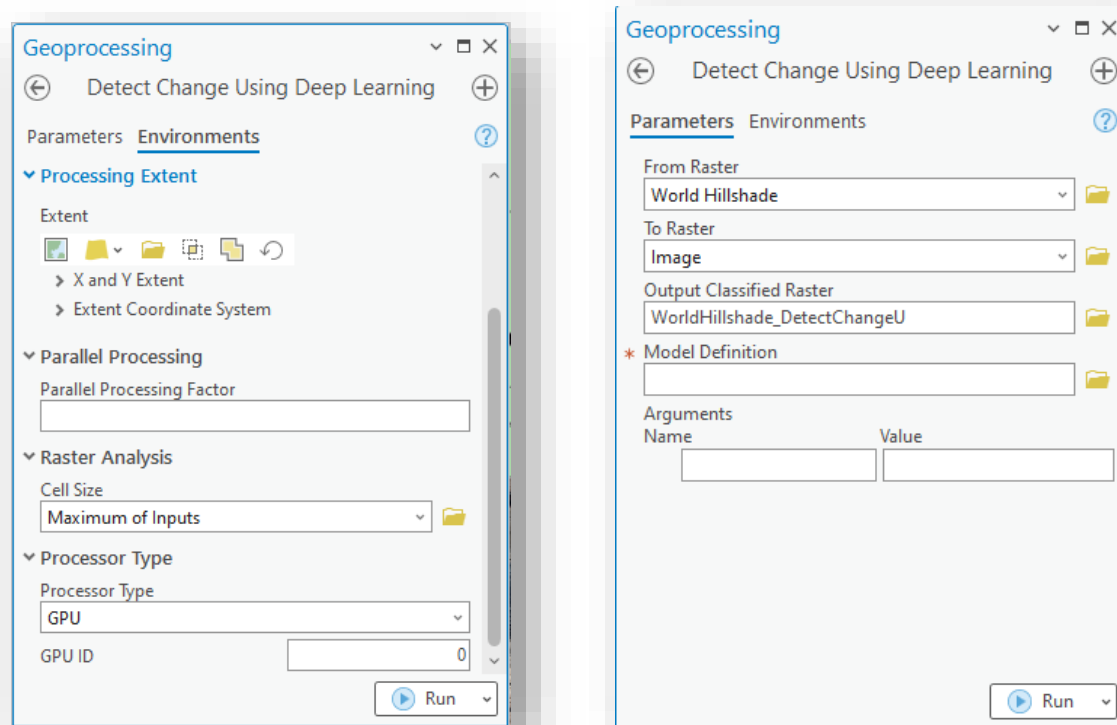


متوسط الدقة AP : هو متوسطات الدقة عبر جميع قيم الاستدعاء بين 0 و 1. يمكن تفسير AP على أنه إيجاد المنطقة الواقعة أسفل منحنى استدعاء الدقة. من خلال الاستيفاء عبر جميع النقاط، يمكن تفسير AP على أنها المنطقة الواقعة أسفل منحنى الاسترجاع الدقيق.

متوسط الدقة mAP : هو متوسط AP عبر عتبات IoU المتعددة. على سبيل المثال، يتوافق $mAP@[0.5:0.05:0.95]$ مع AP لقيم نسبة IoU التي تتراوح من 0.5 إلى 0.95، على فترات زمنية قدرها 0.05، متوسطاً على جميع الفئات.

أداة Detect Change Using Deep Learning

تستخدم هذه الأداة لاستخراج التغيرات باستخدام التعلم العميق حيث يتم الكشف عن التغير في منطقة محددة من خلال الصور المتاحة لهذه المنطقة خلال هذه الفترة فمتطلبات الاداة صورة بتاريخ قديم وصورة بتاريخ أحدث ونموذج تعلم عميق لاكتشاف الظواهر المطلوب الكشف عن التغير فيها) وذلك كما موضح بالصورة التالية :



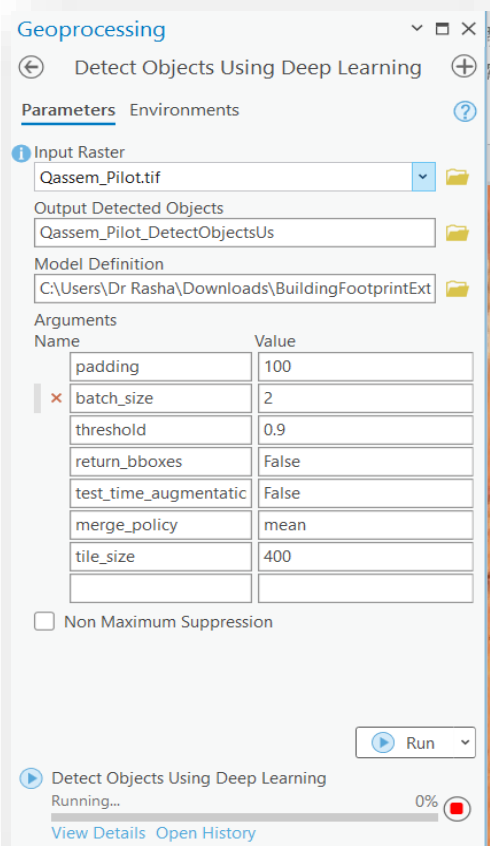
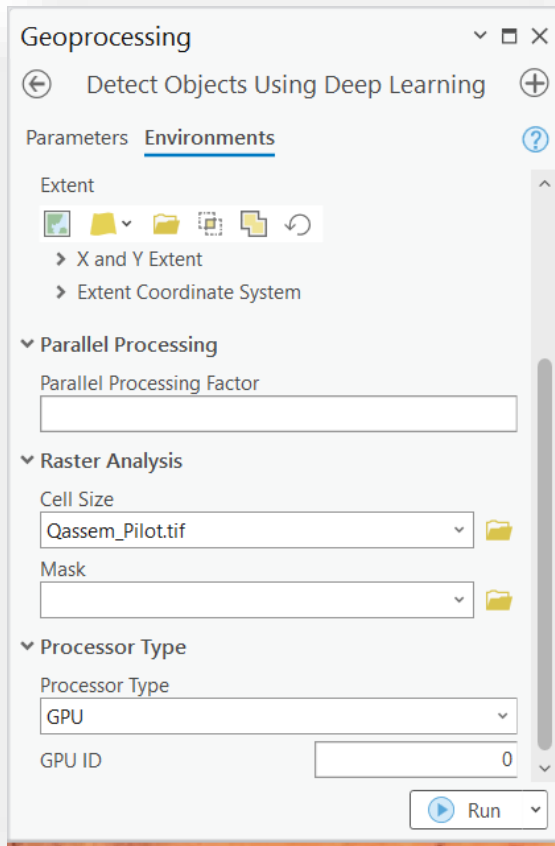
أداة Detect Object Using Deep Learning

تستخدم هذه الأداة لاكتشاف الكائنات من الصور الجوية والفضائية ؛ مثل استخراج المباني أو استخراج الطرق و السيارات وخلافه

متطلبات الأداة : الصورة التي يتم استخراج الظاهرات منها ؛ ونموذج مدرب على استخراج الظاهرة المطلوبة وهناك متطلبات ادخال اختيارية مثل :

Padding: عدد وحدات البكسل الموجودة على حدود مربعات الصورة التي يتم من خلالها مزج التنبؤات للمربعات المجاورة.

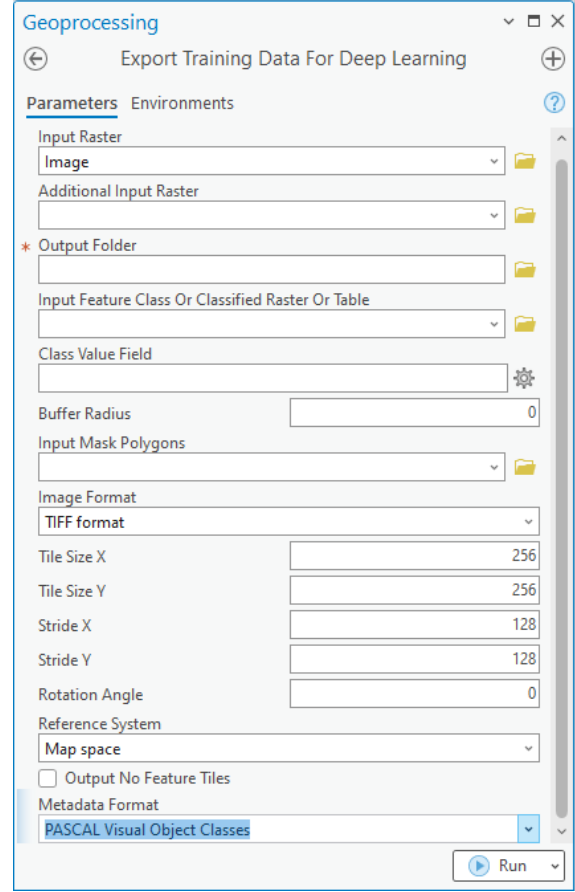
Batch size : عدد مربعات الصور التي تمت معالجتها في كل خطوة من خطوات استنتاج النموذج. هذا يعتمد على ذاكرة graphic card للجهاز المستخدم .



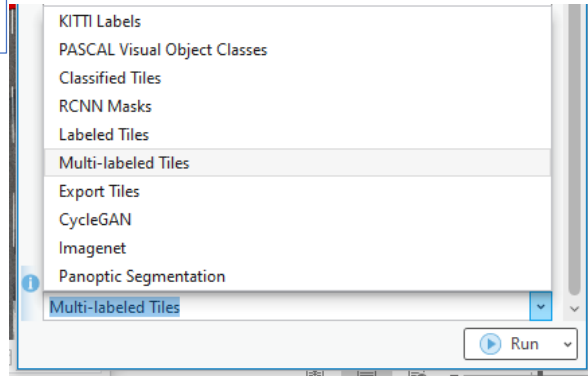
أداة Export Training Data For Deep Learning :

تستخدم هذه الاداة لاستخراج بيانات تدريب لاستخدامها في تدريب النموذج فيما بعد وتتطلب هذه الاداة وجود طبقة تحتوى على عينات تدريبية ؛ فمثلا لو أرادنا استخراج المباني أو الطرق يتم انشاء طبقة ورسم عينات لاستخدامها في استخراج عينات التدريب ويراعى الدقة في أخذ العينات وكذلك محاولة تعدد شكل العينات (تعدد أشكال المباني التي يتم رسمها كعينات تدريب) ؛ فتأخذ الاداة بصمة هذه العينات وتعطى لنا بأمتلة مختلفة لها لاستخدامها في تدريب نموذج تعلم عميق .

- 1- الطبقة المراد اخراج عينات تدريبية منها وتكون من نوع Raster
- 2- مكان استخراج البيانات (لا بد أن يكون مجلد فارغ)
- 3- الطبقة التي تم استخدامها لاختذ العينات
- 4- الحقل المراد استخراج البيانات التدريبية على اساسه
- 5- طبقة يتم وضعها كـماسك
- 6- حجم عينات التدريب المراد استخراجها
- 7- نسبة التداخل في الصور المستخرجة (عينات التدريب)
- 8- النظام المرجعي للبيانات المستخرجة
- 9- تنسيق البيانات (النموذج المستخدم لاستخراج البيانات)



تحديد التنسيق الذي سيتم استخدامه لتسميات بيانات تعريف الإخراج



إذا كانت بيانات عينة التدريب المدخلة عبارة عن feature class، مثل طبقة مبانى أو ملف نموذج تدريب standard classification، فاستخدم خيار KITTI Labels أو PASCAL Visual Object Classes. يتطابق اسم ملف البيانات التعريفية مع اسم الصورة المدخلة. وإذا كانت بيانات نموذج التدريب عبارة عن class map، فيتم استخدام Classified Tiles

KITTI Labels: ستتبع البيانات الوصفية نفس التنسيق الذي يتبعه معهد كارلسروه للتكنولوجيا ومعهد تويوتا التكنولوجي (KITTI) لمجموعة بيانات تقييم اكتشاف الكائنات؛ مجموعة بيانات KITTI عبارة عن مجموعة معايير للرؤية. ملفات التسمية هي ملفات نصية عادية. يتم فصل جميع القيم، الرقمية والنصوص، بمسافات، ويتوافق كل صف مع كائن واحد. يستخدم هذا التنسيق للكشف عن الكائنات.

بالنسبة لتنسيق بيانات تعريف KITTI، يتم إنشاء 15 عمودًا، ولكن يتم استخدام 5 منها فقط في الأداة. العمود الأول هو قيمة الفئة. يتم تخطي الأعمدة الثلاثة التالية. تحدد الأعمدة من 5 إلى 8 الحد الأدنى للمستطيل المحيط، والذي يتكون من أربعة مواقع إحداثيات للصورة: وحدات البكسل اليسرى والعلوية واليمنى والسفلية. يشمل الحد الأدنى للمستطيل المحيط شريحة التدريب المستخدمة في مصنف التعلم العميق. لا يتم استخدام الأعمدة المتبقية.

PASCAL Visual Object Classes: ستتبع البيانات التعريفية نفس تنسيق مجموعة بيانات تحليل الأنماط والنمذجة الإحصائية والتعلم الحسابي وهي عبارة عن مجموعة بيانات صور موحدة للتعرف على Object Classes ويستخدم هذا التنسيق للكشف عن الكائنات.

Classified Tiles: سيكون الإخراج عبارة عن شريحة صورة مصنفة واحدة لكل شريحة صورة مُدخلة. لا يتم استخدام أي بيانات وصفية أخرى لكل شريحة صورة. يُستخدم هذا التنسيق بشكل أساسي لتصنيف البكسل. و لاكتشاف التغيير.

RCNN Masks: سيكون الإخراج عبارة عن شرائح من الصور تحتوي على قناع في المناطق التي توجد بها العينة. يقوم النموذج بإنشاء مربعات محيطية وأقنعة تجزئة لكل مثل للظاهرة في الصورة. يعتمد هذا التنسيق على شبكة (FPN) و (ResNet101) في نموذج إطار عمل التعلم العميق. يستخدم هذا التنسيق للكشف عن الكائنات؛ ومع ذلك، يمكن استخدامه أيضًا لتتبع الكائنات عند استخدام نموذج Siam Mask أثناء التدريب، بالإضافة إلى تصنيف وحدات البكسل للسلسلة الزمنية عند استخدام بنية PSETAE.

Labeled Tiles: سيتم تسمية كل مربع مخرج بفئة معينة. يستخدم هذا التنسيق لتصنيف الكائنات.

Multi-labeled Tiles: سيتم تسمية كل مربع مخرجات بفئة واحدة أو أكثر. يستخدم هذا التنسيق لتصنيف الكائنات.

Export Tiles: سيكون الإخراج عبارة عن شرائح صور بدون ملصق. يستخدم هذا التنسيق في تقنيات ترجمة الصور، مثل Supersolution و Pix2Pix.

CycleGAN: سيكون الناتج عبارة عن شرائح صور بدون ملصق. يستخدم هذا التنسيق لتقنية ترجمة الصور CycleGAN، والتي تُستخدم لتدريب الصور غير المتداخلة.

Imagnet : سيتم تسمية كل لوحة مخرجات بفئة معينة. يستخدم هذا التنسيق لتصنيف الكائنات؛ ومع يمكن

استخدامه أيضًا لتتبع الكائنات عند استخدام نوع نموذج الفرز العميق " Sort model " أثناء التدريب.

Panoptic Segmentation: سيكون الناتج عبارة عن شريحة صورة مصنفة واحدة ومثيل واحد لكل شريحة صورة مُدخلة.

سيحتوي الإخراج أيضًا على شرائح صور تخفي المناطق التي توجد بها العينة؛ سيتم تخزين شرائح الصور هذه في مجلد

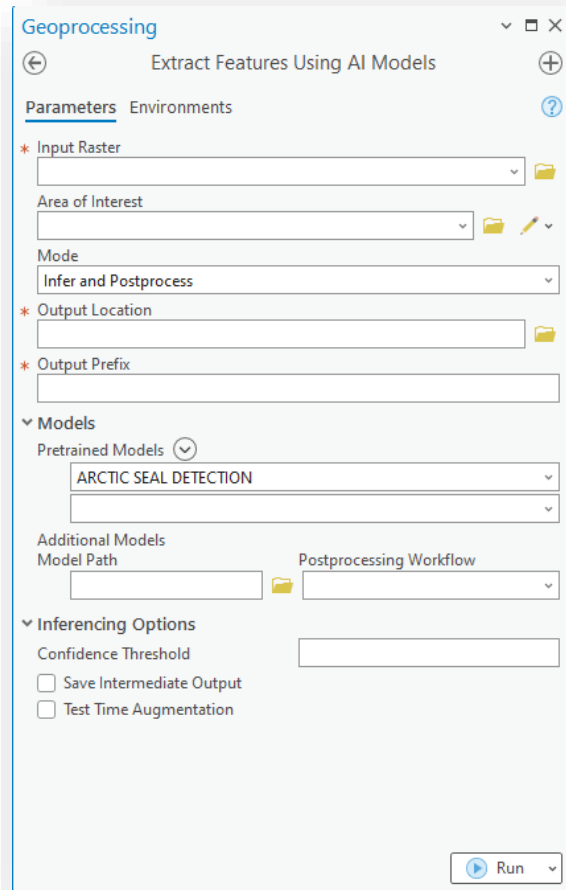
مختلف. يتم استخدام هذا التنسيق لكل من تصنيف البكسل وتجزئة المثيلات، لذلك سيتم إنتاج مجلدين لتسميات

الإخراج.


أداة Extract Features Using AI Models

تستخدم لتشغيل نموذج تعلم عميق مدرب من قبل أو أكثر على البيانات من نوع Raster المدخلة لاستخراج Features

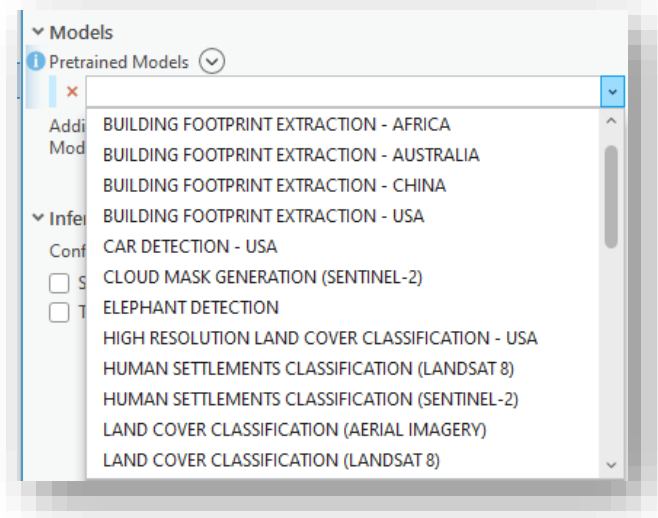
وأتمتة المعالجة اللاحقة للمخرجات المستنتجة.



- 1- Input Raster: الطبقة المطلوب العمل عليها.
- 2- Area of Interest: النطاق الجغرافي الذي سيتم استخدامه لاستخراج المعالم. حيث يتم استخراج الميزات الموجودة في منطقة الاهتمام فقط
- 3- Mode : يحدد الوضع الذي سيتم استخدامه لمعالجة البيانات النقطية المدخلة



- الاستدلال والمعالجة اللاحقة : سيتم استخراج الميزات من الصور ومعالجتها لاحقًا. هذا هو الافتراضي.
- المعالجة اللاحقة فقط :ستتم معالجة البيانات النقطية المدخلة مباشرة بعد المعالجة. من المتوقع وجود بيانات نقطية ذات نطاق واحد مع تصنيف ثنائي لهذا الخيار.
- 4- **Out put Location** : تحديد موقع البيانات المستخرجة.
- 5- **Out put Prefix** : ستتم إضافتها إلى اسم المخرجات التي سيتم حفظها في موقع الإخراج. أو كاسم لطبقة المجموعة التي سيتم استخدامها لعرض جميع المخرجات.
- 6- **Models** : نماذج ArcGIS المدربة مسبقًا من ArcGIS Living Atlas of the World والتي يمكن استخدامها في البيانات النقطية المدخلة المتوفرة. تتطلب اتصالاً بالإنترنت لتنزيل النماذج المدربة مسبقًا.

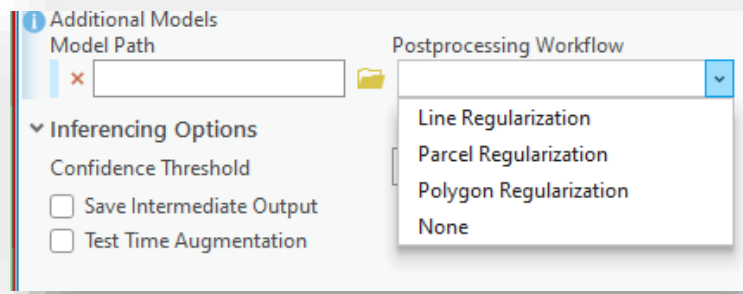


7- ولأن الاداة تقوم باستخراج الميزات المطلوبة من الصور باستخدام نماذج الذكاء الاصطناعي المدربة مسبقاً. يمكن أن تكون نماذج الذكاء الاصطناعي إما نماذج ArcGIS مُدربة مسبقاً من ArcGIS Living Atlas of the World أو حزم نماذج تعلم عميق تم إنشاؤها (dlpk) تعمل الأداة مع الصور وتسمح بالاختيار من بين العديد من النماذج سواء اكتشاف الكائنات أو تصنيف البكسل المدربة مسبقاً والتي يمكنها استخراج الظاهرات (الميزات) من الصور ، تقوم الأداة بشكل اختياري بإجراء المعالجة اللاحقة على المخرجات لإنشاء نتائج محسنة. من الممكن أيضاً إجراء المعالجة اللاحقة للنتائج التي تم إنشاؤها مسبقاً فقط باستخدام هذه الأداة. تقوم الأداة بإنشاء group layer تحتوي على كافة الميزات المستخرجة.



أي أن الأداة تقوم تلقائياً بتنفيذ خطوات ما بعد المعالجة لنماذج ArcGIS المدربة مسبقاً. يمكن أيضاً استخدام مسارات عمل ما بعد المعالجة هذه مع النماذج المتوافقة الأخرى التي تم تدريبها باستخدام ArcGIS. يتيح ذلك إنشاء نتائج منقحة دون تشغيل أدوات معالجة جغرافية متعددة.

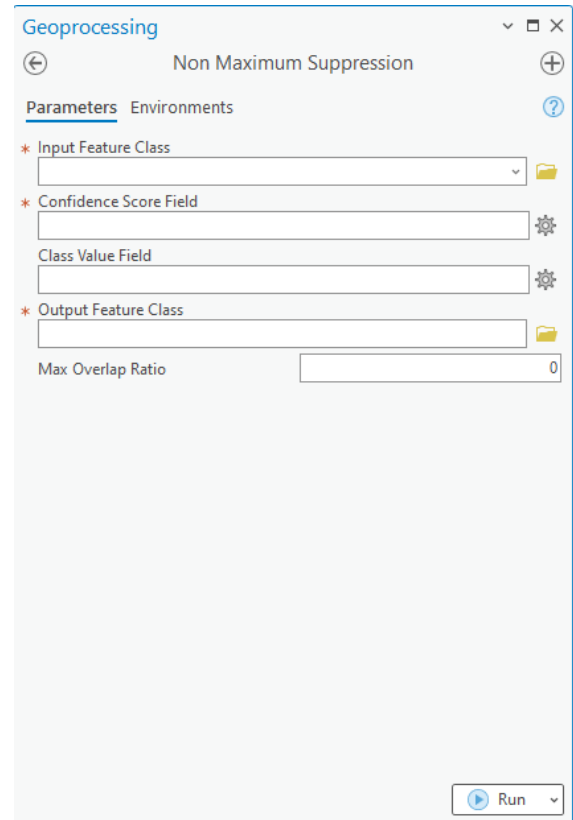
تتوفر عمليات سير عمل ما بعد المعالجة لتنظيم Lines و Parcel، بالإضافة إلى تنظيم المضلعات. يعمل تنظيم Lines و Parcel مع البيانات النقطية أحادية النطاق ذات التصنيف الثنائي، ويعمل تنظيم المضلع فقط مع features من نوع المضلع. ويجب أخذ هذه الجوانب في الاعتبار أثناء تطبيق المعالجة اللاحقة على نماذج إضافية. تتطلب الأداة تراخيص ملحقة (3 Analyst, D Analyst, Spatial Analyst, and Production Mapping) لتشغيل سير عمل المعالجة اللاحقة. إذا لم يكن أي من هذه الملحقات متاحاً، فسيتم تخطي خطوات المعالجة اللاحقة وسيتم إنشاء المخرجات الأولية فقط بواسطة الأداة.



أداة Non Maximum Suppression :

يحدد الميزات المكررة من مخرجات أداة Detect Objects Using Deep Learning كخطوة ما بعد المعالجة وإنشاء مخرجات جديدة بدون ميزات مكررة. يمكن لأداة Detect Objects Using Deep Learning إرجاع أكثر من مربع محيط أو مضلع لنفس الكائن، خاصة كتأثير جانبي للتجانس. إذا تداخلت معلمتان مع نسبة قصوى معينة، فستتم إزالة الميزة ذات قيمة الثقة الأقل.

الطبقة المراد تدقيقها
الحقل الموجود في فئة المعالم الذي يحتوي على درجات الثقة
الحقل الذي يحتوي على القيمة .
احتيار مكان حفظ البيانات المخرجة .
الحد الأقصى للتداخل.

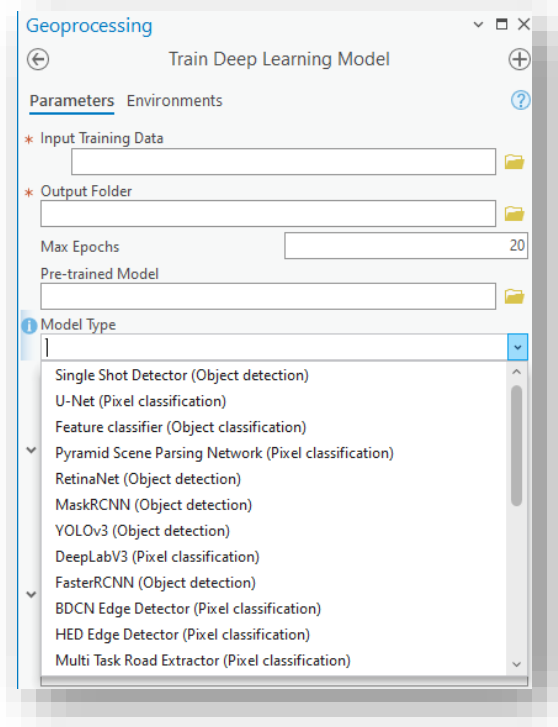


يجب أن تحتوي feature class على حقل ثقة بقيمة ثقة لكل معلم. و إذا كانت feature class تحتوي على أكثر من فئة ظاهرة مثل الأشجار أو السيارات أو المباني - فيجب أن تحتوي أيضًا على حقل class value أو class name. و إذا كان هناك معلمان متداخلان لديهما نسبة تداخل أكبر من الحد الأقصى لنسبة التداخل المحددة، فستتم إزالة المعلم ذو الثقة الأقل. تقوم الأداة أولاً بمراجعة فئة المعالم لكل فئة كائن على حدة، وتضع علامة على الميزات المكررة ذات الثقة الأقل المراد إزالتها. ثم يقوم بمراجعة جميع الميزات، ومقارنة ميزات فئات الكائنات المختلفة و الإخراج عبارة عن feature class جديدة مع إزالة الميزات المكررة المكتشفة.

أداة Train Deep Learning Model :

تستخدم الاداة بيانات التدريب لتدريب نموذج تعلم عميق عليها ؛ حيث يتم ادخالها في طبقة الادخال :

ويتم اختيار النموذج المطلوب من انواع النماذج المتوفرة :



يحدد نوع النموذج الذي سيتم استخدامه لتدريب نموذج التعلم العميق وتعدد النماذج المتوفرة داخل الأداة على النحو التالي:

Single Shot Detector (Object detection): يستخدم SSD للكشف عن الكائنات. تستخدم بيانات التدريب المدخلة لهذا

النوع من النماذج تنسيق Pascal Visual Object Classes metadata البيانات التعريفية لفئات الكائنات المرئية من Pascal.

U-Net (Pixel classification): يتم استخدام بنية U-Net لتدريب النموذج. يتم استخدام U-Net لتصنيف البكسل.

Feature classifier (Object classification): يتم استخدام بنية مصنف الميزات لتدريب النموذج. يستخدم النموذج

لتصنيف الكائنات أو الصور.

Pyramid Scene Parsing Network (Pixel classification): يتم استخدام بنية شبكة تحليل المشهد الهرمي (PSPNET)

لتدريب النموذج. يتم استخدامه لتصنيف البكسل.

RetinaNet (Object detection): يتم استخدام بنية RetinaNet لتدريب النموذج. يتم استخدام RetinaNet للكشف عن

الكائنات.

MaskRCNN (Object detection): يستخدم MaskRCNN للكشف عن الكائنات. يتم استخدام هذا الأسلوب عن طريق

تجزئة الكائنات المطلوب استخراجها فيتم التحديد الدقيق للكائنات في الصورة. يمكن استخدام هذا النوع من النماذج

للكشف عن المباني. ويستخدم تنسيق البيانات التعريفية MaskRCNN لبيانات التدريب كمدخلات. يجب أن تبدأ قيم الفئة

لبينات تدريب الإدخال عند 1 و لا يمكن تدريب هذا النوع من النماذج إلا باستخدام وحدة معالجة الرسومات CUDA التي تدعم GPU .

YOLOv3 (Object detection) : يتم استخدام YOLOv3 للكشف عن الكائنات.

DeepLabV3 (Pixel classification) : يستخدم DeepLab لتصنيف البكسل.

FasterRCNN (Object detection) : يتم استخدام FasterRCNN للكشف عن الكائنات.

BDCN Edge Detector (Pixel classification) : يتم استخدام كاشف الحافة BDCN لتصنيف البكسل. يعد هذا الأسلوب مفيداً لتحسين اكتشاف الحواف للكائنات بمقاييس مختلفة.

HED Edge Detector (Pixel classification) : يستخدم (HED) لتصنيف البكسل. يعد هذا الأسلوب مفيداً في اكتشاف حدود الحافة والكائن.

Multi Task Road Extractor (Pixel classification) : يتم استخدامه لتصنيف البكسل. وهذا النهج مفيد لاستخراج شبكة الطرق من صور الأقمار الصناعية.

ConnectNet (Pixel classification) : يتم استخدام ConnectNet لتصنيف البكسل. وهذا النموذج أيضاً مفيد لاستخراج شبكة الطرق من صور الأقمار الصناعية.

Pix2Pix (Image translation) : تستخدم Pix2Pix للترجمة من صورة إلى صورة. يقوم هذا الأسلوب بإنشاء كائن نموذجي يقوم بإنشاء صور من نوع إلى آخر.

CycleGAN (Image translation) : يستخدم CycleGAN للترجمة من صورة إلى صورة يعد هذا الأسلوب فريداً من نوعه حيث أن الصور التي سيتم تدريبها لا تحتاج إلى تداخل. تستخدم بيانات التدريب المدخلة لهذا النوع من النماذج تنسيق البيانات التعريفية. CycleGAN.

Super-resolution (Image translation) : الدقة الفائقة للترجمة من صورة إلى صورة. يقوم هذا الأسلوب بإنشاء كائن نموذجي يزيد من الدقة ويحسن جودة الصور.

Change detector (Pixel classification) : يستخدم هذا النموذج لتصنيف البكسل. يقوم هذا الأسلوب بإنشاء Object نموذجي يستخدم صورتين مكانيتين وزمانيتين لإنشاء بيانات نقطية (طبقة جديدة) مصنفة للتغيرات بين الصورتين.

Image captioner (Image translation) : يستخدم هذا النموذج لترجمة الصورة إلى نص. حيث يقوم بإنشاء نموذج يقوم بإنشاء تسميات توضيحية نصية لصورة ما.

Siam Mask (Object tracker) : يستخدم Siam Mask للكشف عن الأشياء في مقاطع الفيديو. يتم تدريب النموذج باستخدام إطارات الفيديو ويكتشف الفئات والمربعات المحيطة بالكائنات في كل إطار.

MMSegmentation (Pixel classification) : يستخدم النموذج لتصنيف البكسل.

Deep Sort (Object tracker) : يستخدم الفرز العميق لاكتشاف الكائنات في مقاطع الفيديو. يتم تدريب النموذج باستخدام إطارات الفيديو ويكتشف الفئات والمربعات المحيطة بالكائنات في كل إطار. تستخدم بيانات تدريب الإدخال لهذا النوع من النماذج تنسيق بيانات تعريف. Imagenet. في حين أن Siam Mask مفيد لتتبع كائن ما، و Deep Sort مفيد في تدريب النموذج على تتبع كائنات متعددة.

Pix2PixHD (Image translation) : ستم استخدام بنية Pix2PixHD لتدريب النموذج. يستخدم Pix2PixHD للترجمة من صورة إلى صورة.

MaX-DeepLab (Panoptic segmentation): يستخدم MaX-DeepLab للتجزئة الشاملة. يقوم هذا الأسلوب بإنشاء كائن نموذجي يقوم بإنشاء الصور والميزات.

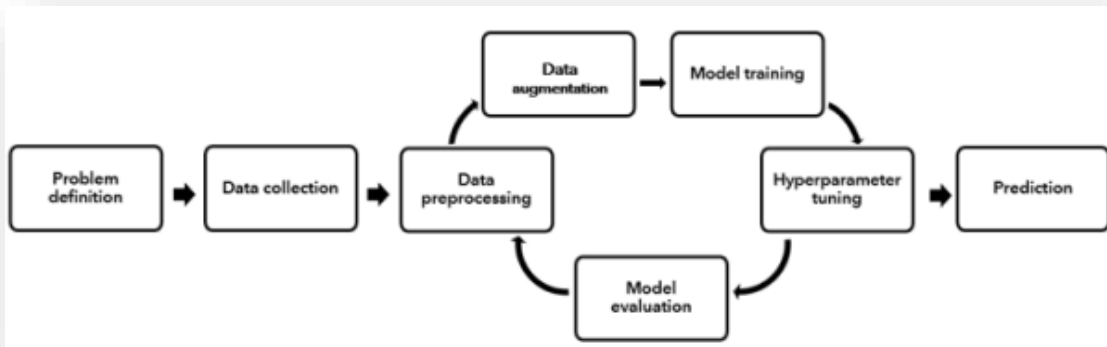
DETReg (Object detection) : يتم استخدام DETReg للكشف عن الكائنات. تستخدم بيانات التدريب المدخلة لهذا النوع من النماذج فئات Pascal Visual Object. هذا النوع من النماذج يستخدم وحدة معالجة الرسومات بشكل مكثف؛ فهو يتطلب وحدة معالجة رسومات مخصصة بذاكرة لا تقل عن 16 جيجابايت لتعمل بشكل صحيح.

PSETAE (Pixel classification): سيتم استخدامه لتدريب النموذج على تصنيف السلاسل الزمنية.

أداة Train Using AutoDL :

تستخدم هذه الأداة لتدريب نموذج تعلم عميق من خلال بناء مسارات تدريب وأتمتة جزء كبير من عملية التدريب. يتضمن ذلك زيادة البيانات واختيار النموذج و تتضمن مخرجاتها مقاييس أداء أفضل نموذج في بيانات التدريب، بالإضافة إلى حزمة نموذج التعلم العميق المدرب ملف (dlpk) التي يمكن استخدامه .

يبدأ سير عمل مشروع التعلم العميق النموذجي (DL) بتحديد مشكلة العمل وطرح سؤال المشكلة . ويتبع ذلك سلسلة من الخطوات، بما في ذلك إعداد البيانات (أو المعالجة المسبقة)، والتدريب على النماذج، وضبط الظواهر الفائقة، وتقييم النموذج. هذه عملية تكرارية وغالبًا ما يتم الوصول إلى النموذج الأمثل بعد تكرارات وتجارب متعددة.



يستغرق تحديد النموذج الذي يناسب البيانات بشكل أفضل الكثير من الوقت والجهد والخبرة فتعمل أداة التدريب باستخدام AutoDL على أتمتة سير العمل بأكمله وتحديد أفضل الشبكات العصبية مع أفضل مجموعة من المعلمات الفائقة التي تناسب البيانات.

نطاق العمل بالأداة:

زيادة البيانات: تتطلب مشاريع التعلم عن بعد الناجحة كميات هائلة من بيانات الإدخال عالية الجودة لمعالجة مشكلة معينة. ومع ذلك، من الصعب في الواقع الحصول على بيانات مصنفة بكميات كبيرة. فيتم تطبيق تقنيات زيادة البيانات من أجل زيادة كمية البيانات بحيث تشبه بيانات العالم الحقيقي. يمكن أن تتضمن زيادة البيانات تحويلات هندسية، والاقتصاص، والترجمة، وإزالة الضوضاء وما إلى ذلك، وكل ذلك قد يتطلب كثيراً من الوقت والجهد وتعتبر هذه الخطوة من الخطوات المملة وقد تتطلب معرفة وخبرة تفصيلية خاصة بالمجال.

الخصم التلقائي من batch size: تصدير بيانات التدريب باستخدام أداة التعلم العميق عبارة عن مجلد يحتوي على مجموعة بيانات. تحتوي هذه البيانات على كمية كبيرة من الصور، والتي يجب إرسالها على دفعات بناءً على الموارد المتاحة. تقوم الأداة بآتمتة عملية حساب حجم الدفعة الأمثل لتدريب نموذج التعلم العميق بناءً على الموارد المتاحة.

التدريب النموذجي واختيار النموذج: في خطوة التدريب على النموذج، يختار ممارس التعلم عن بعد شبكة التعلم عن بعد المناسبة بناءً على المشكلة وخصائص البيانات. ثم يبدأون العملية التكرارية لنماذج التدريب لتناسب مع البيانات، والتي غالباً ما تتضمن تجربة العديد من شبكات DL العصبية المختلفة. قد تحتوي كل من هذه الخوارزميات على العديد من المعلمات الفائقة المختلفة hyperparameters ، وهي قيم يتم تحديدها يدوياً بواسطة ممارس التعلم العميق والتي تتحكم في كيفية تعلم النموذج. يتم بعد ذلك ضبط هذه المعلمات الفائقة وتعديلها محاولة لتحسين أداء الخوارزمية وتحقيق نتائج أفضل. هذه عملية المتكررة تتطلب الوقت والخبرة وتضمن نماذج الشبكات العصبية المختلفة نماذج الكشف عن الكائنات مثل

SingleShotDetector و RetinaNet و YoloV3 و FasterRCNN و MMDetection. و نماذج تصنيف البكسل مثل UnetClassifier و PSPNetClassifier و DeepLab و MMSegmentation وكلاهما يعمل بشكل أفضل على بيانات معينة. من الصعب التنبؤ بالنماذج التي ستعمل بشكل جيد على مجموعة بيانات معينة، لذلك يجب عليك تجربة جميع النماذج لمقارنة أدائها قبل اتخاذ قرار بشأن النموذج الذي يناسب البيانات بشكل أفضل.

ضبط المعلمات الفائقة Hyperparameter : على الرغم من أن معظم الخطوات السابقة كانت متكررة، إلا أن الخطوة التي غالبًا ما تكون الأكثر صعوبة أثناء تدريب نماذج التعلم الآلي هي ضبط المعلمات الفائقة. يمكن اعتبارها بمثابة أدوات مساعدة تأتي مع كل نموذج.

تقييم النموذج: الخطوة الأخيرة في سير عمل DL هي تقييم النموذج، حيث نتحقق من أن شبكات DL العصبية المدربة والمضبوطة سوف تعمم بشكل جيد على البيانات التي لم يتم تركيبها عليها. غالبًا ما يُشار إلى هذه البيانات غير المرئية باسم مجموعة التحقق أو الاختبار ويتم الاحتفاظ بها منفصلة عن بقية البيانات المستخدمة لتدريب النموذج. الهدف من هذه الخطوة النهائية هو التأكد من أن شبكات DL تنتج دقة تنبؤية مقبولة للبيانات الجديدة.

في سير عمل DL، هناك درجات متفاوتة من المدخلات البشرية، وصنع القرار، والاختيار الذي يحدث في كل خطوة.

وهناك مجموعة من التساؤلات الواجب طرحها الآن منها :

هل تم جمع البيانات المناسبة لمعالجة المشكلة، وهل هناك ما يكفي منها؟

إذا تم العثور على بيانات ذات تسمية خاطئة، فما الذي يجب أن يحل محلها؟

كم عدد العصور التي يجب تدريب نموذج DL عليها؟

ما هي الشبكة العصبية DL التي يجب استخدامها؟

ما هو مستوى الأداء المقبول للنموذج؟

ما هو أفضل مزيج من المعلمات الفائقة لنموذج معين؟

من المحتمل أن يتضمن هذا القرار الأخير مئات أو حتى آلاف المجموعات من المعلمات الفائقة التي يمكن تكرارها. إذا قمنا بتدريب العديد من شبكات DL وضبطها، فستصبح العملية برمتها غير قابلة للإدارة وغير منتجة. بالإضافة إلى ذلك، تتطلب العديد من الخطوات في سير عمل DL فهمًا فنيًا متخصصًا لتقنيات علم البيانات والإحصائيات وخوارزميات التعلم العميق. على هذا النحو، قد يستغرق تصميم مشاريع التعلم عن بعد وتشغيلها وقتًا طويلاً، ويتطلب عمالة كثيفة، ومكلفًا، وغالبًا ما يعتمد بشكل كبير على ممارسي التعلم عن بعد المدربين وعلماء البيانات.

وفي العقد الماضي، شهد التعلم العميق نموًا سريعًا في كل من نطاق التطبيقات التي يتم تطبيقه عليها وكمية الأبحاث الجديدة المنتجة عليها. بعض أكبر القوى الدافعة وراء هذا النمو هي نضج خوارزميات وأساليب DL نفسها، وتوليد ونشر كميات هائلة

من البيانات لتتعلم منها الخوارزميات، ووفرة الحوسبة غير المكلفة لتشغيل الخوارزميات، وزيادة الوعي من بين الشركات أن خوارزميات DL يمكنها معالجة هياكل البيانات والمشكلات المعقدة.

ترغب العديد من المؤسسات في استخدام التعلم العميق للاستفادة من بياناتها واستخلاص رؤى جديدة قابلة للتنفيذ منها، ولكن هناك خلل بين عدد تطبيقات التعلم العميق المحتملة وعدد ممارسيه والخبراء للتعامل معها. ونتيجة لذلك، هناك طلب متزايد على إضفاء الطابع الديمقراطي على التعلم العميق عبر المؤسسات من خلال إنشاء أدوات تجعل الامر متاحًا على نطاق واسع في جميع أنحاء المؤسسة ويمكن استخدامه من قبل خبراء غير متخصصين في التعلم الآلي وخبراء المجال.

ففي الآونة الأخيرة، ظهر التعلم الآلي العميق (AutoDL) كوسيلة لتلبية الطلب الهائل على التعلم العميق داخل المؤسسات بحيث يهدف AutoDL إلى إنشاء نظام واحد لأتمتة (بمعنى آخر، إزالة المدخلات البشرية من أكبر قدر ممكن من سير عمل DL) ؛ بما في ذلك إعداد البيانات، وزيادة البيانات، واختيار النموذج، وضبط المعلمة الفائقة، وتقييم النموذج. ومن خلال القيام بذلك، يمكن أن يكون مفيدًا لغير الخبراء ، و أيضًا لممارسي التعلم العميق المدربين عن طريق التخلص من بعض الخطوات الأكثر ملل واستهلاكًا للوقت في سير عمل التعلم عن بعد.

متطلبات الأداة: ادخال البيانات التدريبية واختيار نوع النموذج المطلوب سواء مبتدئ أو متقدم كما موضح أدناه .

Geoprocessing Train Using AutoDL

Parameters Environments

* Input Training Data

Pretrained Model

* Output Model

Total Time Limit (Hours) 2

AutoDL Mode Basic

Advanced Options

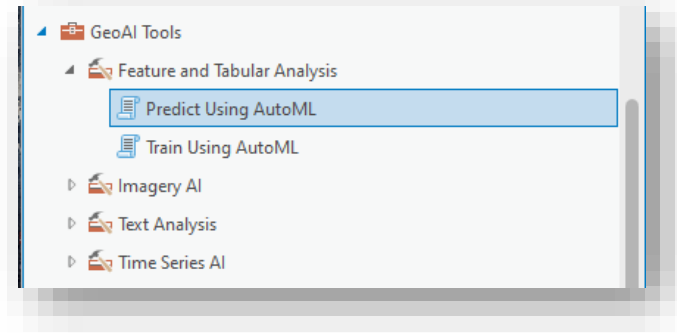
Neural Networks

Save Evaluated Models

Run

مجموعة أدوات GeoAI Tools

: Feature and Tabular Analysis

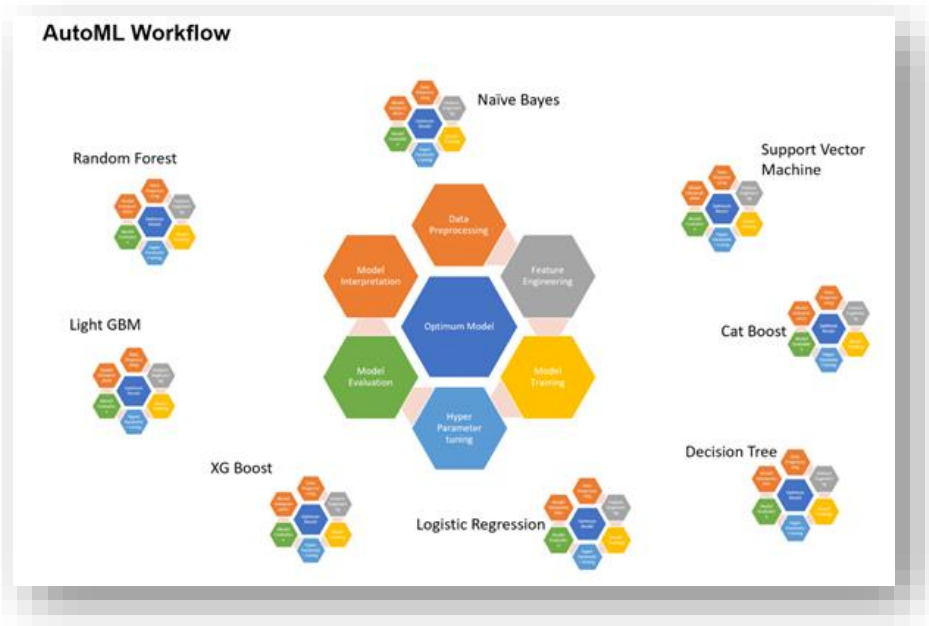


: أداة Predict Using AutoML

يتنبأ بالمتغيرات المستمرة (الانحدار) أو المتغيرات الفئوية (التصنيف) على مجموعات البيانات المتوافقة غير المرئية باستخدام نموذج dlpk المُدرَّب الذي تم إنتاجه بواسطة أداة Train Using AutoML.

في البداية لا بد من معرفة كيف يعمل Auto ML؟

يبدأ سير عمل التعلم الآلي (ML) بتحديد مشكلة العمل وصياغة السؤال مثلته مثل التعلم العميق ويتبع ذلك سلسلة من الخطوات هي نفسها أيضاً والتي تم ذكرها سابقاً (بما في ذلك إعداد البيانات وهندسة الميزات، واختيار الخوارزمية المناسبة والتدريب على النماذج، وضبط المعلمات الفائقة، وتقييم النموذج) هذه عملية تكرارية وغالباً ما يتم الوصول إلى النموذج الأمثل بعد تكرارات وتجارب متعددة.




تقوم أداة التدريب باستخدام AutoML بأتمتة ما يلي:

1- **المعالجة المسبقة للبيانات**: تتطلب مشاريع تعلم الآلة الناجحة مجموعة من بيانات الإدخال عالية الجودة التي تعالج مشكلة معينة. قد تأتي هذه البيانات من مصادر بيانات مختلفة وقد تحتاج إلى دمجها. بمجرد جمع البيانات وتوليئها، يجب تنظيفها وإزالة التشويش منها لضمان إمكانية تدريب خوارزميات التعلم الآلي عليها بشكل فعال والتعلم منها. عادةً ما تستغرق هذه الخطوة وقتًا طويلاً، وقد تتطلب معرفة وخبرة تفصيلية خاصة بالمجال. يمكن أن يتضمن تنظيف البيانات تحديد القيم المفقودة والتعامل معها، والكشف عن القيم المتطرفة، وتصحيح البيانات ذات التسمية الخاطئة، وما إلى ذلك، وكل ذلك قد يتطلب قدرًا كبيرًا من الوقت والجهد من المتخصص و فيما يلي خطوات المعالجة المسبقة:

- **إزالة القيم المتطرفة**: القيم المتطرفة هي نقاط بيانات تختلف عن بقية نقاط البيانات. من أسباب وجود هذه القيم المتطرفة أخطاء إدخال البيانات، أو أخطاء قياس البيانات، أو الاختلاف في المشروع. بغض النظر عن السبب، من المهم إزالة القيم المتطرفة من البيانات، لأنها تؤدي إلى إرباك النموذج أثناء مرحلة التدريب. تتمثل الطرق الشائعة لمعالجة القيم المتطرفة في تصحيح الإدخالات يدويًا أو حذف الإدخالات من مجموعة البيانات.
- **احتساب القيم المفقودة**: قد تحتوي بعض الأعمدة في مجموعة البيانات على إدخالات مفقودة. لا يمكن تدريب نماذج التعلم الآلي إذا كانت هناك إدخالات مفقودة في بيانات التدريب. للتأكد من عدم وجود إدخالات مفقودة في مجموعة البيانات، املأ الإدخالات المفقودة ببيانات صالحة. تتضمن استراتيجيات ملء هذه الإدخالات المفقودة إضافة التكرار الأكثر شيوعًا للقيمة أو إضافة قيمة جديدة لتسليط الضوء على أن البيانات

مفقودة. بالنسبة للبيانات الرقمية، وهناك إحدى الاستراتيجيات هي استخدام المتوسط أو الوسيط لجميع الإدخالات في عمود البيانات المفقودة؛ يمكن تحديد ذلك عن طريق تشغيل أداة Fill Missing Values. تتيح الأداة إمكانية احتساب ليس فقط باستخدام إحصائية من العمود، ولكن أيضًا باستخدام الاستراتيجيات المكانية مثل الجيران المحليين وجيران الزمان والمكان، أو الاستراتيجيات الزمنية مثل قيم السلاسل الزمنية.

- قياس البيانات وتطبيعها: أحد الافتراضات الأساسية أثناء تدريب نموذج خطي للتعلم الآلي مثل OLS هو أن البيانات التي يتم تدريبها يتم توزيعها بشكل طبيعي؛ أي أنه يتبع منحنى bell.



قبل استخدام النموذج الخطي، لا بد من التأكد من توزيع كل عمود في مجموعة البيانات بشكل طبيعي. إذا لم يتم توزيع أي أعمدة بشكل طبيعي، فسيتم تطبيق التحويلات بشكل شائع على البيانات لتحويلها إلى توزيع عادي.

على الرغم من أن ما ورد أعلاه قد يكون صحيحًا بالنسبة للنماذج الخطية، إلا أن الخوارزميات الأخرى مثل الانحدار اللوجستي والنماذج المستندة إلى الشجرة - مثل Decision Tree و Extra Tree و Random Forest و XGBoost و LightGBM - لا تفترض أي حالة طبيعية وتكون أكثر قوة في التعامل مع النماذج الخطية. الاختلافات في الحجم والتوزيعات المنحرفة وما إلى ذلك.

- تحويل البيانات الفئوية إلى رقمية - تتطلب معظم نماذج التعلم الآلي أن تكون البيانات المستخدمة للتدريب في شكل أرقام. لا يمكنهم العمل مع أنواع البيانات الأخرى. قم بتحويل الأعمدة غير الرقمية مثل الولاية أو البلد أو المدينة أو فئة الغطاء الأرضي ونوع البناء والحزب السياسي المسيطر وما إلى ذلك، إلى أرقام. تتضمن التقنيات المستخدمة لتحويل البيانات الفئوية إلى أرقام تشفير المصنقات والتشفير السريع.

-2 **Feature engineering**: تسمى الأعمدة المستخدمة أثناء عملية تدريب النموذج الميزات. تختلف فائدة هذه الميزات أثناء تعلم النموذج. قد لا تكون بعض الميزات مفيدة، وفي هذه الحالات، يتحسن النموذج عند إزالة الميزات من مجموعة البيانات.

هناك بعض الأساليب مثل recursive feature elimination وتقنيات random feature في تحديد مدى فائدة الميزات الموجودة في مجموعة البيانات، ويتم إزالة الميزات غير المفيدة في مثل هذه الأساليب بشكل عام. في بعض الحالات، يؤدي دمج ميزات متعددة في ميزة واحدة إلى تحسين النموذج. وتسمى هذه العملية هندسة الميزات.

وبصرف النظر عن الميزات الجديدة التي تم الحصول عليها من خلال الجمع بين ميزات متعددة من الإدخال، تقوم الأداة أيضًا بإنشاء ميزات مكانية بأسماء من Zone3_id إلى Zone7_id عند استخدام الخيار المتقدم. يتم إنشاء هذه الميزات الجديدة عن طريق تعيين موقع ميزات تدريب الإدخال لشبكات مكانية متعددة (حتى خمسة) بأحجام مختلفة واستخدام معرفات الشبكة كمتغيرات مستقلة فتوية تسمى Zone3_id حتى Zone7_id. وهذا يوفر المعلومات المكانية ذات الصلة للنماذج ويساعدهم على تعلم المزيد من البيانات المتاحة.

- 3- تدريب النموذج واختيار النموذج: في خطوة تدريب النموذج، يختار ممارس تعلم الآلة خوارزمية تعلم الآلة المناسبة بناءً على المشكلة وخصائص البيانات. ثم يبدأون العملية التكرارية لنماذج التدريب لتناسب البيانات، والتي تتضمن غالبًا تجربة العديد من خوارزميات تعلم الآلة. قد تحتوي كل من هذه الخوارزميات على العديد من المعلمات الفائقة المختلفة، وهي قيم يتم تحديدها يدويًا بواسطة المستخدم والتي تتحكم في كيفية تعلم النموذج. يتم بعد ذلك ضبط المعلمات الفائقة في محاولة لتحسين أداء الخوارزمية وتحقيق نتائج أفضل. تشمل الخوارزميات أو النماذج الإحصائية المتنوعة على الانحدار الخطي والانحدار اللوجستي، ونماذج التعلم الآلي الأخرى مثل أشجار القرار، والغابات العشوائية، ونماذج التعزيز الأحدث مثل LightGBM و XGBoost على الرغم من أن XGBoost و LightGBM يتفوقان على معظم النماذج الأخرى في جميع مجموعات البيانات تقريبًا، إلا أنه من الصعب التنبؤ بالنماذج التي ستعمل بشكل جيد على مجموعة بيانات معينة، لذلك يجب تجربة جميع النماذج لمقارنة أدائها قبل اتخاذ قرار بشأن النموذج الذي يناسب البيانات بشكل أفضل؛ يتم إرجاع مقاييس النماذج المختلفة بعد تدريب نماذج الانحدار والتصنيف التي تقوم بتشغيل أداة التدريب باستخدام AutoML بالنسبة لبعض هذه المقاييس، تشير القيمة الأعلى إلى نموذج أفضل، وبالنسبة للآخرين، تشير القيمة الأقل إلى نموذج أفضل.
- 4- تجميع النموذج: في معظم الحالات، يؤدي دمج نماذج متعددة في نموذج واحد وأخذ المخرجات من هذا النموذج المدمج إلى تفوق النتيجة من نموذج واحد. وتسمى هذه الخطوة تجميع النموذج.
- 5- ضبط المعلمات الفائقة: وهي الخطوة الأكثر صعوبة أثناء تدريب نماذج التعلم الآلي.
- 6- اختيار النموذج: الخطوة الأخيرة في سير عمل تعلم الآلة هي تقييم النموذج، حيث يمكن التحقق من أن خوارزمية تعلم الآلة المدربة والمضبوطة سوف تعمم بشكل جيد على البيانات التي لم يتم تركيبها عليها. غالبًا ما يُشار إلى هذه البيانات غير المرئية باسم مجموعة التحقق أو الاختبار ويتم الاحتفاظ بها منفصلة عن بقية البيانات المستخدمة لتدريب النموذج. الهدف من هذه الخطوة النهائية هو التأكد من أن خوارزمية ML تنتج دقة تنبؤية مقبولة للبيانات الجديدة.

في الآونة الأخيرة، ظهر التعلم الآلي الآلي (AutoML) كوسيلة لتلبية الطلب على تعلم الآلة في المؤسسات وتهدف AutoML إلى إنشاء نظام واحد لأتمتة أكبر قدر ممكن من سير عمل تعلم الآلة، بما في ذلك إعداد البيانات، وهندسة الميزات، واختيار النموذج، وضبط المعلمات الفائقة، وتقييم النموذج. ومن خلال القيام بذلك، يمكن أن يكون مفيدًا لغير الخبراء من خلال

تقليل حاجز الدخول إلى تعلم الآلة، و أيضاً لممارسي تعلم الآلة المدربين من خلال التخلص من بعض الخطوات في سير عمل تعلم الآلة.

يمكن أن يساعد AutoML أيضاً في تعزيز إنتاجية ممارسي تعلم الآلة لأنه يلغي بعض الاختيارات الذاتية والتجريب المتضمن في سير عمل تعلم الآلة. على سبيل المثال، قد يكون لدى ممارس تعلم الآلة الذي يقترب من مشروع جديد التدريب والخبرة اللازمة لإرشاده بشأن الميزات الجديدة التي يجب إنشاؤها، وأي خوارزمية تعلم الآلة قد تكون الأفضل لمشكلة معينة، وأي المعلومات الفائقة هي الأكثر مثالية. ومع ذلك، فقد يتجاهلون إنشاء ميزات جديدة معينة أو يفشلون في تجربة جميع المجموعات الممكنة من المعلومات الفائقة أثناء تنفيذ سير عمل تعلم الآلة. بالإضافة إلى ذلك، قد يتحيز ممارس تعلم الآلة في عملية اختيار الميزات أو اختيار الخوارزمية لأنهم يفضلون خوارزمية تعلم الآلة المعينة بناءً على عملهم السابق أو نجاحها في تطبيقات تعلم الآلة الأخرى. في الواقع، لا توجد خوارزمية واحدة للتعلم الآلي تحقق أفضل أداء في جميع مجموعات البيانات ؛ يمكن أن يساعد AutoML في تقليل بعض هذا التحيز البشري من خلال تطبيق العديد من خوارزميات ML المختلفة على نفس مجموعة البيانات ثم تحديد أي منها يحقق أفضل أداء.

بالنسبة لممارس تعلم الآلة، يمكن أن يكون AutoML بمثابة نقطة بداية أولية أو معيار مرجعي في مشروع تعلم الآلة. ويمكنهم استخدامه لتطوير نموذج أساسي لمجموعة بيانات تلقائياً، مما يمكن أن يمنحهم رؤية أولية حول مشكلة معينة. قد يقررون إضافة ميزات محددة أو إزالتها من مجموعة بيانات الإدخال أو التركيز على خوارزمية تعلم الآلة المحددة وضبط المعلومات الفائقة الخاصة بها. وبهذا المعنى، يمكن النظر إلى AutoML كوسيلة لتضييق مجموعة الاختيارات الأولية لممارس ML المدرب، حتى يتمكنوا من التركيز على تحسين أداء نظام ML بشكل عام. يعد هذا سير عمل شائع الاستخدام حيث يقوم خبراء تعلم الآلة بتطوير معيار يعتمد على البيانات باستخدام AutoML والبناء على هذا المعيار من خلال دمج خبراتهم لتحسين النتائج.

يسمح توحيد تعلم الآلة باستخدام AutoML في المؤسسة لخبراء المجال بتركيز اهتمامهم على مشكلة العمل والحصول على نتائج قابلة للتنفيذ، ويسمح لمزيد من المحللين ببناء نماذج أفضل، ويمكن أن يقلل من عدد خبراء تعلم الآلة الذين تحتاجهم المؤسسة. ويمكن أن يساعد أيضاً في تعزيز إنتاجية ممارسي تعلم الآلة وعلماء البيانات المدربين، مما يسمح لهم بالتركيز على العديد من المهام الأخرى التي تشتت الحاجة إليها.

تحديد النموذج الأفضل

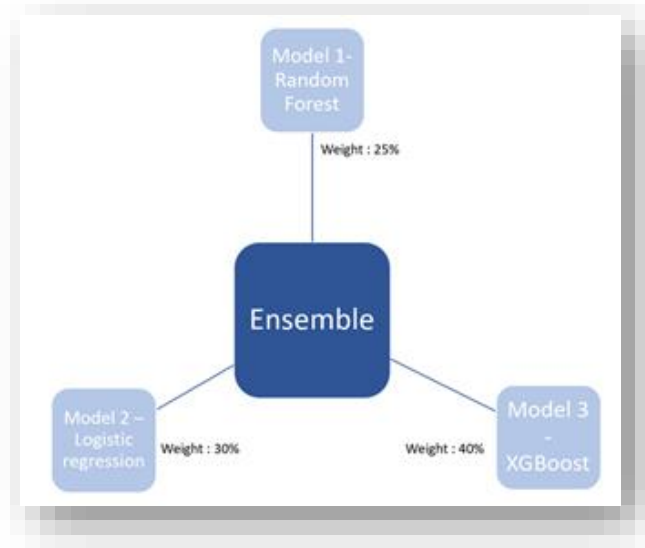
لتحديد أفضل نموذج باستخدام أداة التدريب باستخدام AutoML، يتبع الخطوات التالية:

1. تشغيل خوارزميات بسيطة، مثل شجرة القرار (شجرة بسيطة بحد أقصى للعمق 4) والنماذج الخطية. وهذا يسمح بإجراء فحص سريع للبيانات بالإضافة إلى النتائج المتوقعة.
2. تدريب النماذج المحددة من الخطوة السابقة باستخدام المعلومات الافتراضية من خلال مجموعة من الخوارزميات الأكثر تعقيداً باستخدام المعلومات الفائقة الافتراضية. تتم محاولة ملاءمة نموذج واحد لكل خوارزمية ولجميع الخوارزميات المتاحة (Linear و Random Forest و XGBoost و LightGBM و Decision Tree و Extra Tree).
3. إجراء بحث عشوائي عبر مساحة المعلومات الفائقة لكل خوارزمية للعثور على المجموعة المثالية من المعلومات الفائقة.

4. إنشاء ميزات جديدة عن طريق تحديد أيًا من الميزات الجديدة تتمتع بقدرة تنبؤية، وإضافتها إلى مجموعة البيانات الأصلية.
5. استخدم المجموعة المثالية من المميزات الفائقة المحددة في الخطوة 4 لتدريب نموذج واحد أفضل أداءً لكل خوارزمية، وتحديد الميزات الأقل أهمية وإزالتها. ؛ يتم دمج النتائج من أفضل النماذج التي تم تدريبها حتى الآن. ثم يتم تكديس النماذج ودمج نتائج أفضل النماذج (بما في ذلك النماذج المكسدة).

إنشاء ensemble

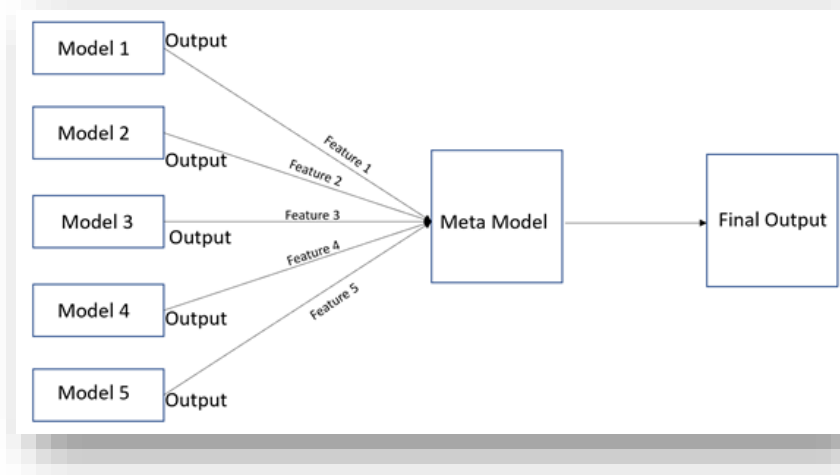
ensemble عبارة عن مجموعة من النماذج التي يتم دمج توقعاتها عن طريق المتوسط المرجح أو التصويت.



الاستراتيجيات الأكثر شيوعًا لإنشاء ensemble هي (Random Forest) والتي تجمع بين مخرجات النماذج التي تنتمي إلى نفس الخوارزميات .

لإنشاء ensemble ، يمكن اتباع الخطوات التالية:

1. إضافة النموذج الموجود في المكتبة والذي يعمل على زيادة أداء المجموعة إلى الحد الأقصى لمقياس الخطأ في مجموعة التحقق من الصحة.
 2. تكرار الخطوة السابقة لعدد محدد من التكرارات أو إضافة كافة النماذج.
 3. إرجاع المجموعة من مجموعة المجموعات المتداخلة التي تتمتع بأقصى أداء في مجموعة التحقق من الصحة.
- يتضمن تكديس النماذج الجمع بين نتائج نماذج متعددة واستخلاص النتيجة منها.



في حين أن أساليب التجميع تجمع بين نتائج النماذج المختلفة من خلال تطبيق أوزان مختلفة على المخرجات، فإن التراص يستخدم مخرجات كل نموذج أساسي كمميزات ويضيفها إلى نموذج عالي المستوى: نموذج تعريفي. يتم استخدام مخرجات النموذج التعريفي ذي المستوى الأعلى كمخرج نهائي.

تفسير تقارير المخرجات


يمكن لأداة التدريب باستخدام AutoML إنشاء تقرير HTML كمخرج.

تعرض الصفحة الرئيسية للتقرير لوحة المتصدرين. تتوفر نفس المعلومات أيضًا في نافذة إخراج الأداة.

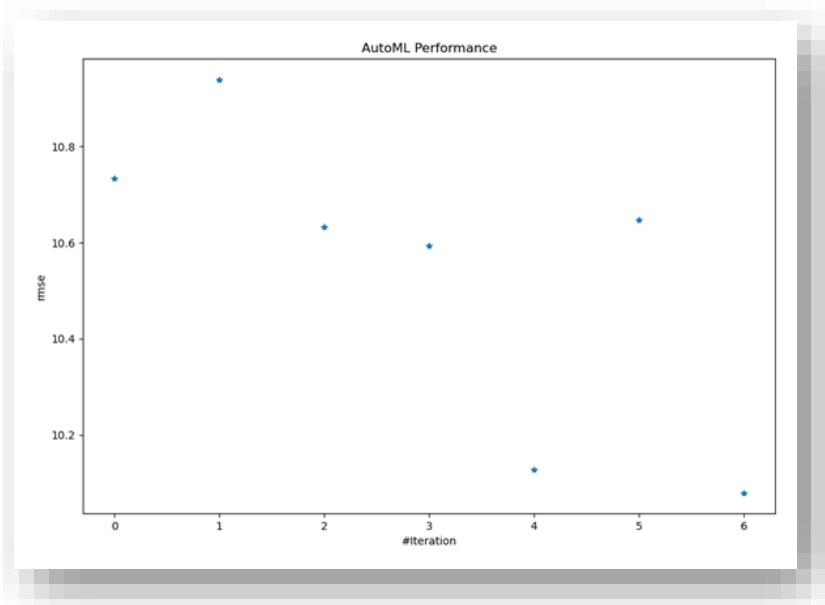
Best model	name	model_type	metric_type	metric_value	train_time
	1_DecisionTree	Decision Tree	rmse	251909	11.92
	2_Default_LightGBM	LightGBM	rmse	258718	3.92
	3_Default_Xgboost	Xgboost	rmse	256129	3.85
	4_Default_RandomForest	Random Forest	rmse	250765	5.15
	5_Default_ExtraTrees	Extra Trees	rmse	265653	4.88
the best	Ensemble	Ensemble	rmse	247234	0.48

تعرض لوحة المتصدرين النماذج التي تم تقييمها وقيمها المترية. بالنسبة لمشكلة الانحدار، يعتبر النموذج ذو أقل RMSE هو النموذج الأفضل (في هذه الحالة، نموذج ensemble).


يقارن مخطط مربع أداء AutoML أدناه مقياس التقييم للنماذج المختلفة بمقياس التقييم (RMSE) على المحور y والنماذج على المحور x، كما هو موضح أدناه. يوضح مخطط الصندوق أن أفضل نموذج هو نموذج المجموعة الذي يحتوي على أقل RMSE.



يوضح مخطط أداء AutoML أدناه كيف يختلف مقياس التقييم للنموذج الأفضل أداءً، وهو في هذه الحالة نموذج ensemble ، عبر التكرارات المختلفة. يمكن أن يساعد مخطط التكرار في فهم مدى اتساق النموذج عبر عمليات التشغيل المختلفة للنموذج.



يتم إنشاء ارتباط سببىرمان الموضوع أدناه لجميع النماذج التي تم تقييمها، وتظهر النماذج الأكثر ارتباطاً بظلال داكنة من اللون الأزرق. على سبيل المثال، تعد مخرجات LightGBM و XGBoost هي الأكثر ارتباطاً (وهذا أمر متوقع، حيث أن كلاهما يعزز الخوارزميات). يشبه الإخراج من LightGBM الإخراج من Random Forest مقارنةً بالإخراج من Extra Trees.



من لوحة المتصدرين، يمكن النقر فوق الرابط الخاص بأي من النماذج الموجودة في عمود الاسم للانتقال إلى صفحة تعرض المعلومات الفائقة التي تم الانتهاء منها لتدريب النموذج بعد إكمال ضبط المعلمات الفائقة. في هذا المثال، تم تدريب شجرة القرار بقيمة max_depth تبلغ 3.

Decision Tree


- `n_jobs`: -1
- `criterion`: mse
- `max_depth`: 3
- `explain_level`: 2


تعرض نفس الصفحة أيضًا مقاييس أخرى بخلاف تلك التي تم استخدامها للتقييم. في المثال أدناه، والذي كان عبارة عن مهمة انحدار، تم استخدام مقاييس MAE و MSE و RMSE و R2 و MAPE لتقييم النموذج.

Metric details:


Metric	Score
MAE	167416
MSE	6.34579e+10
RMSE	251909
R2	0.549962
MAPE	0.357589

يتم أيضًا عرض المخطط المبعثر للمخرجات الفعلية والمتوقعة (لعينة مكونة من 5000 نقطة بيانات). يمكن استخدام هذا المخطط لتحديد أداء النموذج. توضح الأشكال أعلاه مقارنة المخططات المبعثرة لنموذجين تم الحصول عليهما من التقرير. النموذج الثاني يقدم أداء أفضل من الأول، حيث تتباعد القيم المتوقعة والحقيقية بشكل أكبر.






ولجعل النماذج أكثر قابلية للتفسير، يتم تضمين أهمية كل متغير في النموذج النهائي في التقرير على غرار أهمية الميزة. في الرسم البياني أدناه، يمكن تصور التأثير العالمي لكل متغير في مجموعة بيانات الإسكان على النموذج المُدرَّب. وهذا يوضح أن خاصية sqft_living هي الأكثر تأثيراً على النموذج وهي الميزة الأكثر أهمية، يليها عدد Bathrooms وغرف النوم مع التنبؤ بأسعار المنازل.



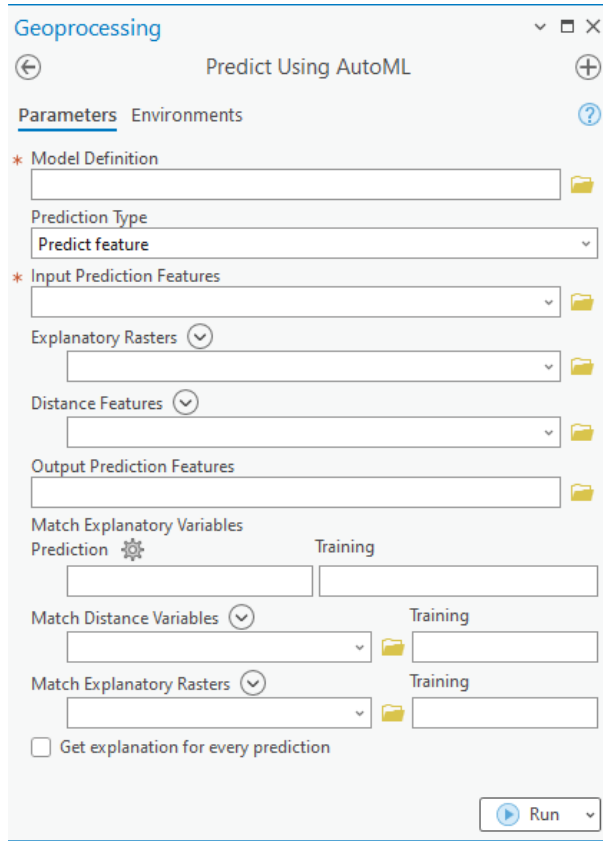
باستخدام الخيار Basic، لدينا خيار رؤية تقرير تحليل البيانات الاستكشافية التلقائي (تقرير EDA) الذي يطبع إحصائيات ملخصة للمتغير المستهدف والمتنبئات المستخدمة في تدريب النموذج. ما يلي هو نموذج لتقرير EDA لمتغير يسمى altclip.tif:

Feature : altclip.tif

- Feature type : continous
- Missing : 0.0%
- Unique : 544
- Count :544.0
- Mean :7.955237775714816e-16
- Std :1.0009203867571839
- Min :-1.6838853131011084
- 25 - 50 - 75 - Max :1.7053105989144093 | | |



تطبيق الأداة :



Model Definition: نموذج dlpk المُدرَّب الذي تم إنتاجه بواسطة أداة. Train Using AutoML

Prediction Type: نوع ملف الاخراج المطلوب انشاؤه وهو Feature أو Raster

Input Predict Feature: الطبقة المطلوب الحصول على التنبؤ لها. يجب أن يتضمن الإدخال بعض أو كل الحقول اللازمة لتحديد قيمة المتغير التابع.

Explanatory Rasters: قائمة البيانات النقطية التي تحتوي على البيانات النقطية التوضيحية اللازمة لتحديد قيمة المتغير التابع. هذه المعلمة مطلوبة إذا تم تعيين معلمة نوع التنبؤ على توقع البيانات النقطية.

Distance Feature: تقدير المسافة من ميزات التدريب المدخلة تلقائيًا (معالم النقطة أو المضلعات) وإضافتها كمتغيرات توضيحية.

Match Explanatory Variables: تعيين أسماء الحقول من مجموعة التنبؤ إلى مجموعة التدريب. تستخدم هذه المعلمة إذا كانت أسماء حقول مجموعات التدريب والتنبؤ مختلفة.

Match Explanatory Variables: تعيين أسماء ميزات المسافة من مجموعة التنبؤ إلى مجموعة التدريب. تستخدم هذه المعلمة إذا كانت أسماء ميزات المسافة المستخدمة في مجموعات التدريب والتنبؤ مختلفة.

Match Explanatory Raster: تعيين الأسماء من البيانات النقطية للتنبؤ إلى البيانات النقطية للتدريب. إذا كانت أسماء البيانات النقطية التوضيحية المستخدمة للتنبؤ وأسماء البيانات النقطية المقابلة المستخدمة أثناء التدريب مختلفة.

Get explanation for every Prediction: يحدد ما إذا كان سيتم إضافة الحقول التي تمثل أهمية الميزة فيتم إنشاء الحقول لكل عينة متوقعة بالإضافة إلى قيم التنبؤ.

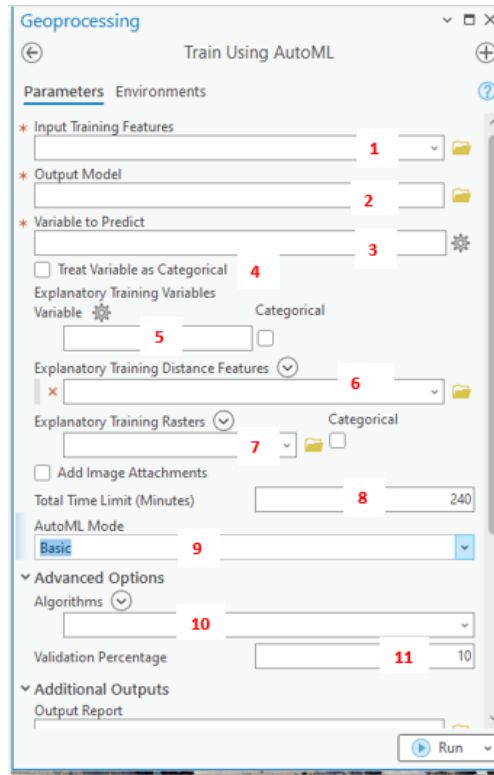
أداة Train Using Auto ML :

تستخدم هذه الأداة لتدريب نموذج تعلم آلة من خلال بناء مسارات تدريب وأتمتة جزء كبير من عملية التدريب؛ تتضمن الصفحة الأولى في تقرير المخرجات روابط لكل نموذج من النماذج التي تم تقييمها وتعرض أدائها في مجموعة بيانات التحقق من الصحة بالإضافة إلى الوقت المستغرق لتدريبها. واستنادًا إلى مقياس التقييم، يعرض التقرير النموذج الأفضل أداءً الذي تم اختياره.

وكما سبق وأن ذكرنا RMSE هو مقياس التقييم الافتراضي لمشكلات الانحدار (التوقع) ، في حين أن Logloss هو المقياس الافتراضي لمشكلات التصنيف. كما تتوفر المقاييس التالية في تقرير المخرجات:

التصنيف: AUC، Logloss، F1، الدقة، متوسط الدقة

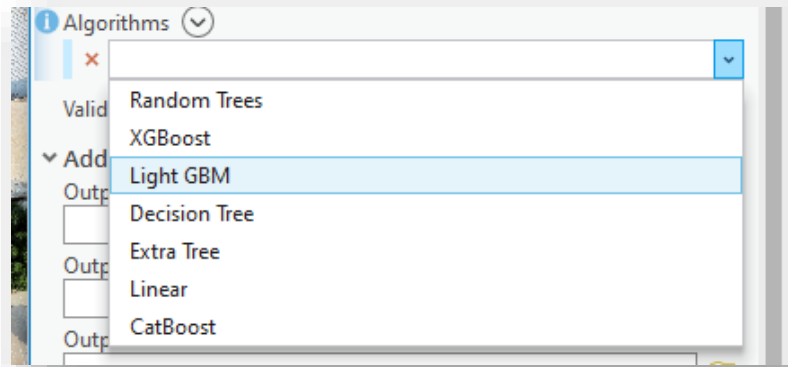
الانحدار: MSE، RMSE، MAE، R2، MAPE، معامل سيرمان، معامل بيرسون؛ عند النقر فوق مجموعة نماذج، يتم عرض تفاصيل حول التدريب الخاص بمجموعة النماذج هذه بما في ذلك منحنيات التعلم ومنحنيات الأهمية المتغيرة والمعلومات الفائقة المستخدمة وما إلى ذلك.



1. الطبقة التي سيتم استخدامها لتدريب النموذج.
2. نموذج الإخراج المدرب الذي سيتم حفظه كحزمة ملف (.dlpk).

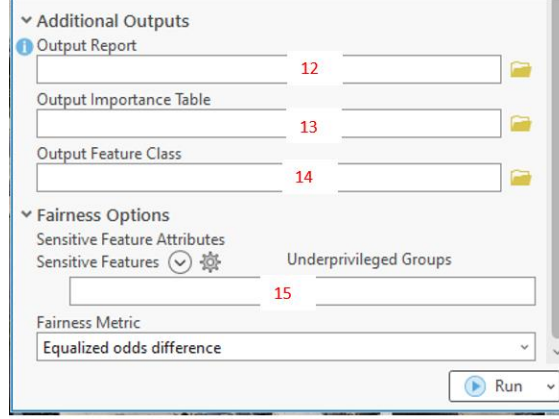
3. حقل من طبقة الإدخال الذي يحتوي على القيم التي سيتم استخدامها لتدريب النموذج.
4. يحدد ما إذا كان سيتم التعامل مع قيمة الظاهرة Variable to Predict كمتغير فئوي. وإذا لم يحدد سيتم التعامل مع قيمة المتغير المراد التنبؤ به على أنه مستمر وسيتم تنفيذ الانحدار.
5. قائمة الحقول التي تمثل المتغيرات التوضيحية التي ستساعد في التنبؤ. ؛ تحديد خانة الاختيار Categorical للبحث عن أي متغيرات تمثل الفئات.
6. الميزات التي سيتم تقدير مسافاتها من ميزات تدريب الإدخال تلقائيًا وإضافتها كمتغيرات توضيحية أكثر.
7. البيانات النقطية التي سيتم استخراج قيمها من البيانات النقطية واعتبارها متغيرات توضيحية للنموذج.
8. إجمالي الحد الزمني بالدقائق الذي يستغرقه التدريب على نموذج AutoML الافتراضي هو 240 (4 ساعات).
9. تحديد نوع النموذج هل هو Basic - Intermediate - Advanced وهذا يؤثر على الوقت المستغرق حيث يتم إجراء مجموعة من العمليات الإضافية في حالة المتقدم مثل هندسة البيانات ؛ وضبط المعلومات الفائقة ؛ يتم استخدام المتوسط لتدريب النموذج الذي سيتم استخدامه في حالات الاستخدام الواقعية حيث يستخدم هذا الوضع التحقق من الصحة المتقاطع بخمسة أضعاف وينتج مخرجات منحنيات التعلم ومخططات الأهمية في التقارير، دون مخططات SHAP غير متوفرة. بينما يتم استخدام المستوى المتقدم للحصول على أقصى قدر من الأداء فيستخدم التحقق المتقاطع بعشرة أضعاف ويقوم بهندسة الميزات وضبط المعلومات الفائقة. يتم تعيين ميزات التدريب على الإدخال إلى شبكات مكانية متعددة بأحجام مختلفة بناءً على موقعها، ويتم تمرير معرفات الشبكة المقابلة كمتغيرات توضيحية فئوية إضافية للنموذج.
10. يحدد الخوارزميات التي سيتم استخدامها أثناء التدريب ؛ بشكل افتراضي، سيتم استخدام كافة الخوارزميات وهناك مجموعة من الخوارزميات المتاحة هي :
 - Linear الخطي: سيتم استخدام خوارزمية الانحدار الخطي الخاضعة للإشراف لتدريب نموذج التعلم الآلي للانحدار. إذا كان هذا هو الخيار الوحيد المحدد، فتأكد من أن إجمالي عدد السجلات أقل من 10.000 وعدد الأعمدة أقل من 1000. يمكن أن تستوعب النماذج الأخرى مجموعات بيانات أكبر ويوصى باستخدام هذا الخيار مع خوارزميات أخرى وليس كخوارزمية وحيدة.
 - Random Tree الأشجار العشوائية: سيتم استخدام خوارزمية التعلم الآلي الخاضعة للإشراف والمبنية على شجرة قرارات الأشجار العشوائية. يمكن استخدامه لكل من التصنيف والانحدار.
 - XGBoost: سيتم استخدام خوارزمية التعلم الآلي الخاضعة للإشراف XGBoost لتعزيز التدرج الشديد يمكن استخدامه لكل من التصنيف والانحدار.

- Light GBM: سيتم استخدام خوارزمية المجموعة المعززة لتدرج Light GBM، والتي تعتمد على أشجار القرار. يمكن استخدامها لكل من التصنيف والانحدار. تم تحسين Light GBM لتحقيق الأداء العالي مع الأنظمة الموزعة.
- Disision Tree شجرة القرار: يتم استخدام خوارزمية التعلم الآلي الخاضعة للإشراف على شجرة القرار، والتي تصنف البيانات باستخدام إجابات صحيحة وخاطئة (0, 1). يمكن فهم أشجار القرار بسهولة وهي جيدة للتفسير.



- Extra Tree الشجرة الإضافية: سيتم استخدام مجموعة الشجرة الإضافية لخوارزمية التعلم الآلي الخاضعة للإشراف، والتي تستخدم أشجار القرار. تشبه هذه الخوارزمية الأشجار العشوائية ولكنها يمكن أن تكون أسرع.
- CatBoost: سيتم استخدام خوارزمية CatBoost ويستخدم أشجار القرار للتصنيف والانحدار.

11. نسبة التحقق من الصحة: النسبة المئوية لبيانات الإدخال التي سيتم استخدامها للتحقق من الصحة. القيمة الافتراضية هي 10.



11- تقرير الإخراج الذي سيتم إنشاؤه كملف .html. فسيتم إنشاء التقرير في مجلد جديد ضمن المسار المقدم. سيحتوي التقرير على تفاصيل النماذج المختلفة بالإضافة إلى تفاصيل العلامات الفائقة التي تم استخدامها أثناء التقييم وأداء كل نموذج.

12- جدول مخرجات يحتوي على معلومات حول أهمية كل متغير توضيحي المستخدمة في النموذج.

13- طبقة المعالم التي تحتوي على القيم المتوقعة بواسطة النموذج الأفضل أداءً في طبقة التدريب. يمكن استخدامه للتحقق من أداء النموذج من خلال مقارنة القيم المتوقعة بصرياً مع الحقيقة الأساسية.

14- تقييم وتحسين عدالة النماذج المدربة للبيانات الجدولية لنماذج التصنيف والانحدار. بتعيين المطلبين التاليين لهذه المعلمة:

- Sensitive Features : سمة مثل العرق أو الجنس أو الحالة الاجتماعية والاقتصادية أو العمر التي يمكن أن تؤدي إلى التحيز في التعلم الآلي أو نماذج التعلم العميق. من خلال اختيار السمات الحساسة مثل العرق أو الجنس أو الحالة الاجتماعية والاقتصادية أو العمر، يتم تخفيف التحيزات المرتبطة بالسمات الحساسة المحددة لنموذج غير متحيز.
- Underprivileged Groups: المجموعة التي تم تمييزها من قيمة الميزة الحساسة المتوفرة.

يمكن شرحها تفصيلياً في هذا الرابط

<https://pro.arcgis.com/en/pro-app/latest/tool-reference/geoai/how-fairness-works.htm>

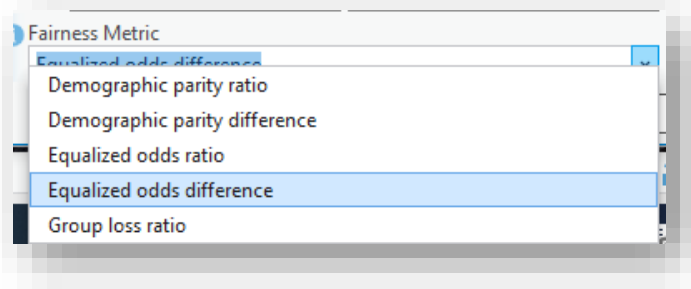
15- يحدد مقاييس العدالة التي سيتم استخدامها لقياس العدالة لمشكلات التصنيف والانحدار، والتي يتم استخدامها لعمليات البحث على الشبكة لاختيار أفضل نموذج عادل وهناك مجموعة من المقاييس هي :

- **Demographic Parity Ratio** نسبة التكافؤ الديموغرافي: يُستخدم هذا المقياس في نماذج التصنيف. وسيتم قياس نسبة معدلات الاختيار بين مجموعات مختلفة من الأفراد. معدل الاختيار هو نسبة الأفراد الذين تم تصنيفهم على أنهم إيجابيون بواسطة النموذج. القيمة المثالية لهذا المقياس هي 1، مما يشير إلى أن معدلات

الاختيار للمجموعات المختلفة متساوية. تتراوح عدالة هذا المقياس بين 0.8 إلى 1، مما يعني أن نسبة معدلات الاختيار بين المجموعات يجب ألا تزيد عن 20 بالمائة.

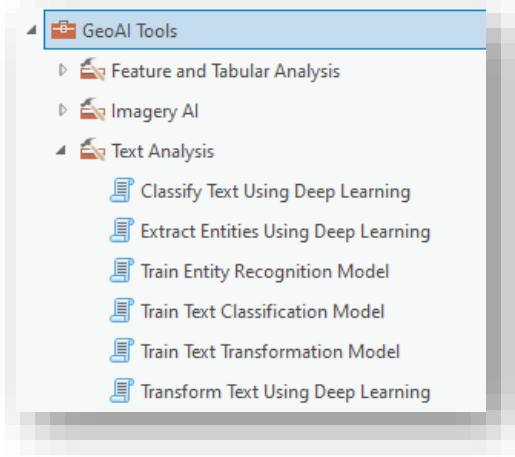
- **Demographic Parity Difference** فرق التكافؤ الديموغرافي: يُستخدم هذا المقياس في نماذج التصنيف. وهو مشابه لمقياس نسبة التكافؤ الديموغرافي، ولكن سيتم قياس الفرق في معدلات الاختيار بين مجموعات مختلفة من الأفراد، وليس النسبة. معدل الاختيار هو نسبة الأفراد الذين تم تصنيفهم على أنهم إيجابيون بواسطة النموذج. القيمة المثالية لهذا المقياس هي 0، مما يشير إلى عدم وجود فرق في معدلات الاختيار بين المجموعات. تتراوح عدالة هذا المقياس بين 0 إلى 0.25، مما يعني أن الاختلافات في معدلات الاختيار بين المجموعات يجب ألا تزيد عن 25 بالمائة.

- **Equalized odds ratio** نسبة الأرجحية المتساوية: يُستخدم هذا المقياس في نماذج التصنيف. سيتم قياس نسبة معدلات الخطأ بين مجموعات الأفراد، مثل المجموعات العرقية المختلفة. القيمة المثالية لهذا المقياس هي 1، مما يشير إلى أن معدلات الخطأ للمجموعات المختلفة متساوية. تتراوح عدالة هذا المقياس بين 0.8 إلى 1، مما يعني أن نسبة الخطأ بين المجموعات يجب ألا تزيد عن 20 بالمائة.



- **Equalized odds difference** فرق الاحتمالات المتساوية: يُستخدم هذا المقياس في نماذج التصنيف. وهو مشابه لمقياس نسبة الأرجحية المتساوية، ولكن سيتم قياس الفرق في الخطأ بين مجموعات مختلفة من الأفراد، بدلاً من النسبة. القيمة المثالية لهذا المقياس هي 0، مما يشير إلى عدم وجود فرق في الخطأ بين المجموعات. تتراوح عدالة هذا المقياس بين 0 إلى 0.25، مما يعني أن الفرق في الخطأ بين المجموعات يجب ألا يزيد عن 25 بالمائة.
- **نسبة خسارة المجموعة**: يُستخدم هذا المقياس في نماذج الانحدار. سيتم قياس نسبة متوسط الخسارة أو الخطأ لمجموعة فرعية واحدة مقارنة بمجموعة فرعية أخرى. ويوفر مقياساً نسبياً للتفاوت في الخسائر بين المجموعات. وتشير القيمة 1 إلى عدم وجود اختلاف في الخسائر بين المجموعتين، في حين تشير القيم الأكبر أو الأصغر من 1 إلى التفاوتات النسبية.

صندوق أدوات Text Analysis



أداة Classify Text Using Deep Learning:

تستخدم هذه الاداة لتصنيف النصوص عن طريق تعيين فئة أو تسمية محددة مسبقاً للجمل أو الفقرات أو التقارير النصية أو غيرها من أشكال النصوص غير المنظمة.

الطبقة أو الجدول الذي يحتوي على النص الذي سيتم تصنيفه وتسميته.

الحقل النصي في طبقة الإدخال أو الجدول الذي يحتوي على النص الذي سيتم تصنيفه.

النموذج المستخدم والمدرّب سابقاً.

اسم الحقل الذي يحتوي على الفئة بواسطة النموذج. اسم الحقل الافتراضي هو ClassLabel.

وسيطات إضافية، مثل التوسيل والطول أو عتبة الثقة، التي سيتم استخدامها لضبط مخرجات النموذج.

عدد عينات التدريب التي سيتم معالجتها في المرة الواحدة. القيمة الافتراضية هي 4. يمكن أن تؤدي زيادة الحجم إلى تحسين أداء الأداة؛ ولكن يتم استخدام المزيد من الذاكرة. وفي حالة حدوث خطأ نفاذ الذاكرة، يتم تصغير الحجم. يتم إنشاء شرح SHAP لكل صف في جدول الإخراج.

Name	Value
sequence_length	512
Batch Size	4

Run

Classify Text Using Deep Learning
Running...
View Details Open History

أداة Extract Entities Using Deep Learning :

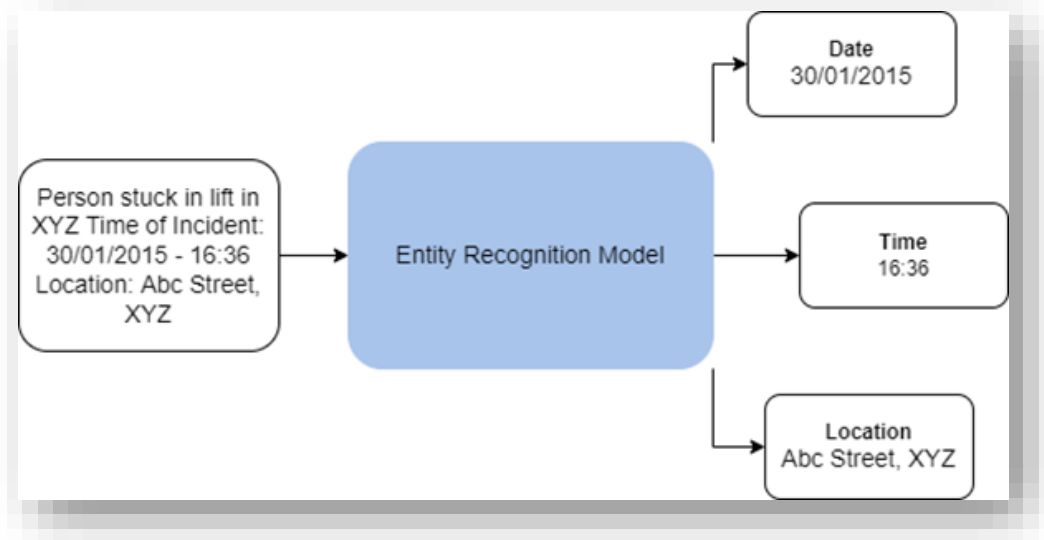
تشغيل نموذج مُدرّب للتعرف على الكيانات المُسمّاة على ملفات نصية في مجلد لاستخراج Entities الكيانات والمواقع (مثل العناوين وأسماء الأماكن أو الأشخاص والتواريخ) في جدول. إذا كانت الكيانات المستخرجة تحتوي على عنوان، تقوم الأداة بتمييز العناوين جغرافيًا باستخدام محدد المواقع المحدد وتنتج فئة المعالم كمخرجات.

ولكن التساؤل الذي يتبادر إلى أذهاننا الآن كيف يعمل نموذج التعرف على الكيان؟

التعرف على الكيان، والمعروف أيضًا باسم التعرف على الكيانات المسمّاة (NER)، هو عملية استخراج المعلومات من الجمل أو الفقرات أو التقارير النصية أو أي شكل من أشكال النص غير المنظم.

تقوم أداة Train Entity Recognition Model tool بتدريب نماذج البرمجة اللغوية العصبية لاستخراج مجموعة محددة مسبقًا من الكيانات (مثل المؤسسات أو الأشخاص أو التاريخ أو البلد) المقدمة كجزء من مجموعة بيانات التدريب. يمكن استخدام نماذج التعرف على الكيانات المدربة مع أداة استخراج الكيانات باستخدام التعلم العميق لاستخراج تلك الكيانات من النص الخام إلى تنسيق منظم.

فيتم استخراج البيانات مثل الموقع أو التاريخ والوقت كما موضح بالشكل أدناه؛ يمكن أن يساعد ذلك في تحديد المناطق التي تحتاج إلى مساعدة فورية أثناء وقوع كارثة طبيعية.

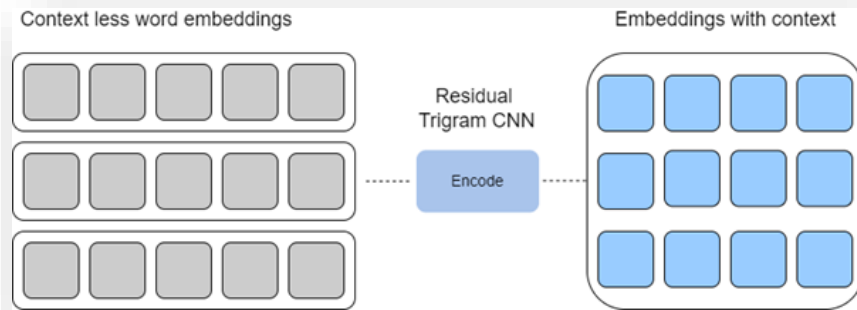


تعتمد نماذج التعرف على الكيانات في ArcGIS على خلفيتين أحدهما تعتمد على بنية Transformer، والأخرى تعتمد على مكتبة spaCy التي تعمل على إطار عمل التضمين والتشفير والحضور والتنبيؤ.

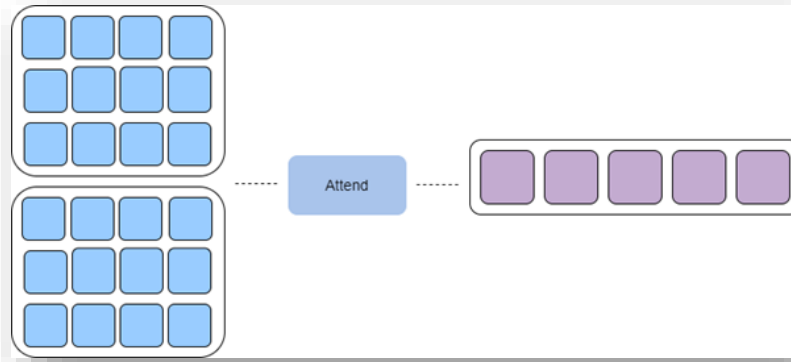
- التضمين : يتم تحويل النص المُدخل إلى تضمينات كثيفة للكلمات. تلتقط هذه التضمينات المعلومات الدلالية من النص المُدخل، كما أنها أسهل بكثير في التعامل مع النموذج.




- التشفير : حيث يتم ترميز السياق في متجه الكلمات. يتم ذلك باستخدام الشبكات العصبية التلافيفية ثلاثية الأبعاد المتبقية (CNN).



- الحضور : يتم تقليل مخرجات المصفوفة من الخطوة السابقة إلى متجه واحد سيتم تمريره للتنبؤ. هذه الخطوة لها تأثير مماثل لآلية الانتباه.

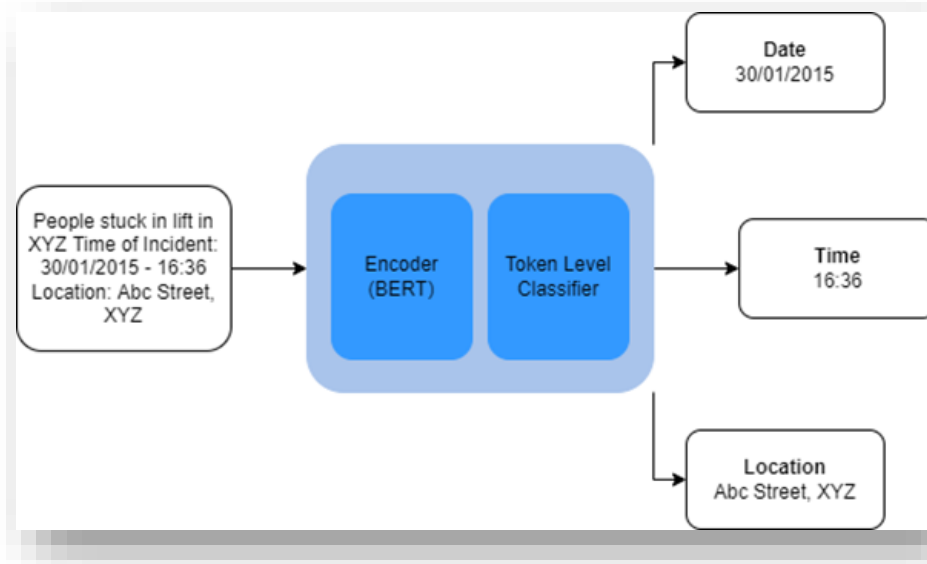


- التنبؤ :الخطوة الأخيرة في النموذج هي إجراء توقع بالنظر إلى النص المُدخل. هنا يتم تمرير المتجه من طبقة الانتباه إلى إدراك متعدد الطبقات لإخراج معرف تسمية الكيان.



، تشمل نماذج التعرف على الكيانات في ArcGIS على مكونين:

- Encoder أداة التشفير: تقوم بتحويل نص الإدخال إلى Feature في شكل vectors ذات حجم ثابت. يستخدم النموذج برامج تشفير معروفة مثل BERT و ALBERT و RoBERTa التي تعتمد على بنية المحولات وتم تدريبها مسبقًا على كميات ضخمة من النصوص.
- Level Classifier مصنف مستوى الرمز المميز: يعمل على تصنيف تمثيل Feature لكل رمز مميز إلى فئات متعددة تمثل الكيانات المختلفة. غالبًا ما يكون المصنف طبقة خطية بسيطة في الشبكة العصبية.



استخدم نماذج التعرف على الكيانات entity recognition model

يمكن استخدام أداة Extract Entities Using Deep Learning لتطبيق نموذج التعرف على الكيانات المدربة على النص غير المنظم واستخراج المعلومات المفيدة منه في شكل بيانات منظمة. يمكن استخدام نماذج التعرف على الكيانات المدربة مسبقًا من ArcGIS Living Atlas of the World أو تدريب نماذج خاصة باستخدام أداة Train Entity Recognition Model.

تقوم الأداة بإنشاء جدول يحتوي على الكيانات المستخرجة من كل ملف نصي في مجلد الإدخال. إذا تم توفير محدد المواقع وتمكن النموذج من استخراج العناوين، فسيتم إنتاج فئة المعالم بدلاً من ذلك عن طريق الترميز الجغرافي للعناوين المستخرجة. إذا كان الملف النصي يحتوي على عناوين متعددة، فسيتم إنشاء الميزة عن طريق الترميز الجغرافي لكل عنوان وتكرار الكيانات الأخرى لهذا الملف النصي.

ملحوظة: يمكن تشغيل الأداة على وحدات المعالجة المركزية (CPUs) ، لكن يوصى استخدام وحدة معالجة الرسومات (GPU) للمعالجة .

أداة Train Entity Recognition Model

تقوم بتدريب نموذج التعرف على الكيان المسعى لاستخراج مجموعة محددة مسبقاً من الكيانات من النصوص الخام.

متطلبات عمل الأداة :

Geoprocessing

Train Entity Recognition Model

Parameters Environments

* Input Folder

Pretrained Model File

* Output Model

Address Entity

Max Epochs 5

Model Parameters

Model Backbone spacy

Batch Size 2

Model Arguments

Name	Value
sequence_length	512

Advanced

Learning Rate

Validation Percentage 10

Stop when model stops improving

Make model backbone trainable

Run

Input Folder : مجلد يحتوي على بيانات التدريب في شكل dataset لمهام NER. ؛ فيما يلي أنواع مجموعات البيانات المدعومة:

- ner_json — يجب أن يحتوي مجلد بيانات التدريب على ملف json. يحتوي على نص وكيانات ذات علامة منسقة باستخدام تنسيق تدريب spaCy JSON.
- IOB تنسيق (I الداخل، O الخارج، B علامات البداية) الذي اقترحه رامشو وماركوس "تقطيع النص باستخدام التعلم القائم على التحويل".

يجب أن يحتوي مجلد بيانات التدريب على الملفين التاليين بتنسيق: csv.

- token.csv يحتوي على نص كأجزاء إدخال.
- tag.csv يحتوي على علامات IOB لأجزاء النص.
- BILUO امتداد لتنسيق IOB الذي يحتوي بالإضافة إلى ذلك على علامتي الوحدة L و U.

يجب أن يحتوي مجلد بيانات التدريب على الملفين التاليين بتنسيق: csv.

- token.csv يحتوي على نص كأجزاء إدخال.

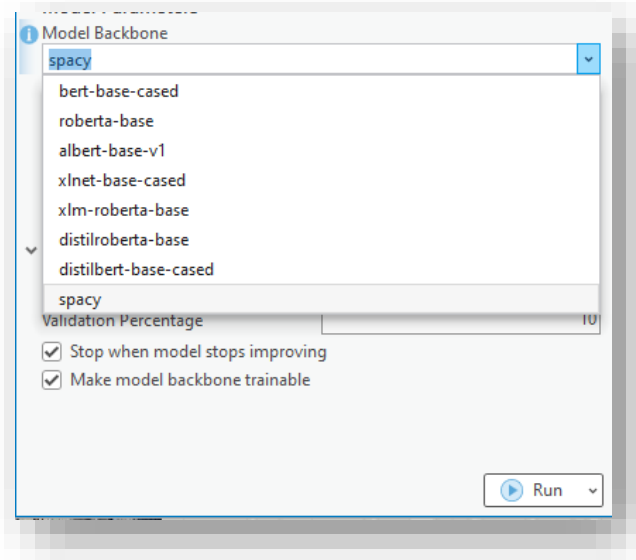
- - tag.csv يحتوي على علامات BILUO لأجزاء النص.

pretrained model File: نموذج تم تدريبه مسبقًا والذي سيتم استخدامه لضبط النموذج الجديد.

Address Entity: كيان عنوان سيتم التعامل معه كموقع. أثناء الاستدلال، سيتم ترميز هذه الكيانات جغرافيًا باستخدام محدد المواقع المحدد، وسيتم إنتاج feature class نتيجة لعملية استخراج الكيان. إذا لم يتم توفير محدد المواقع أو لم يتم النموذج المدرب باستخراج كيانات العنوان، فسيتم إنتاج جدول يحتوي على الكيانات المستخرجة.

Max Epochs: الحد الأقصى لعدد المرات التي سيتم تدريب النموذج عليها. الحد الأقصى لقيمة المرة هو 1 يعني أنه سيتم تمرير مجموعة البيانات للأمام والخلف عبر الشبكة العصبية مرة واحدة. القيمة الافتراضية هي 5.

Model Backbone: يحدد الشبكة العصبية المكونة مسبقًا والتي سيتم استخدامها كبنية لتدريب النموذج الجديد.



- bert-base-cased : سيتم تدريب النموذج باستخدام شبكة BERT العصبية. تم تدريب BERT مسبقًا باستخدام هدف نمذجة اللغة المقنعة والتنبؤ بالجملة التالية.
- roberta-base : سيتم تدريب النموذج باستخدام شبكة RoBERTa العصبية. يقوم RoBERTa بتعديل المعلمات الفائقة الرئيسية لـ BERT، مما يلغي هدف التدريب المسبق وتدريب الجملة التالية بدفعات صغيرة ومعدلات تعلم أعلى.
- albert-base-v1: سيتم تدريب النموذج باستخدام شبكة ALBERT العصبية. يستخدم ALBERT خسارة خاضعة للإشراف الذاتي والتي تركز على نمذجة التماسك البيئي، مما يؤدي إلى قابلية التوسع بشكل أفضل من BERT.
- xlnet-base-cased: سيتم تدريب النموذج باستخدام شبكة XLNet العصبية. XLNet هي طريقة تدريب مسبق ذات انحدار ذاتي معممة. فهو يسمح بتعلم سياقات ثنائية الاتجاه من خلال تعظيم الاحتمالية المتوقعة على جميع التباديل في ترتيب التحليل، مما يتغلب على عيوب BERT.
- xlm-roberta-base : سيتم تدريب النموذج باستخدام الشبكة العصبية XLM-RoBERTa. XLM-RoBERTa هو نموذج متعدد اللغات تم تدريبه على 100 لغة مختلفة. على عكس بعض نماذج XLM متعددة اللغات، لا يتطلب الأمر موترات اللغة لفهم اللغة المستخدمة وتحديد اللغة الصحيحة من معرفات الإدخال.
- distilroberta-base - DistilRoBERTa: هو نموذج للغة الإنجليزية تم تدريبه مسبقًا بإشراف roberta-base فقط على OpenWebTextCorpus، وهو نسخة من مجموعة بيانات WebText الخاصة بـ OpenAI.
- distilbert-base-cased : سيتم تدريب النموذج باستخدام شبكة DistilBERT العصبية. DistilBERT هو نموذج أصغر لتمثيل اللغة للأغراض العامة.

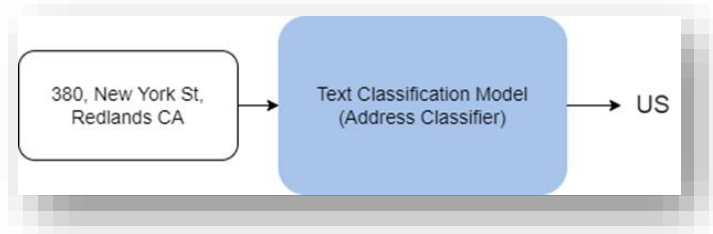
• spacy : سيتم تدريب النموذج باستخدام الشبكة العصبية spacy. Spacy هي مكتبة مفتوحة المصدر لمعالجة اللغات الطبيعية المتقدمة.

Learning Rate: يشير إلى مقدار تعديل أوزان النموذج أثناء عملية التدريب. إذا لم يتم تحديد أي قيمة، فسيتم استنتاج معدل التعلم الأمثل تلقائيًا.

Validation Percentage : النسبة المئوية لعينات التدريب التي سيتم استخدامها للتحقق من صحة النموذج. القيمة الافتراضية هي 10.

أداة Train Text Classification Model


لتدريب نموذج تصنيف نص فردي أو متعدد التسمية لتعيين فئة أو تسمية محددة مسبقًا لنص غير منظم. تقوم أداة Train Text Classification Model بتدريب نماذج البرمجة اللغوية العصبية (NLP) لتصنيف النص بناءً على الفئات أو الفئات المعروفة المقدمة كجزء من مجموعة بيانات التدريب. يمكن استخدام النماذج المدربة مع أداة تصنيف النص باستخدام التعلم العميق لتصنيف النص المماثل إلى تلك الفئات.



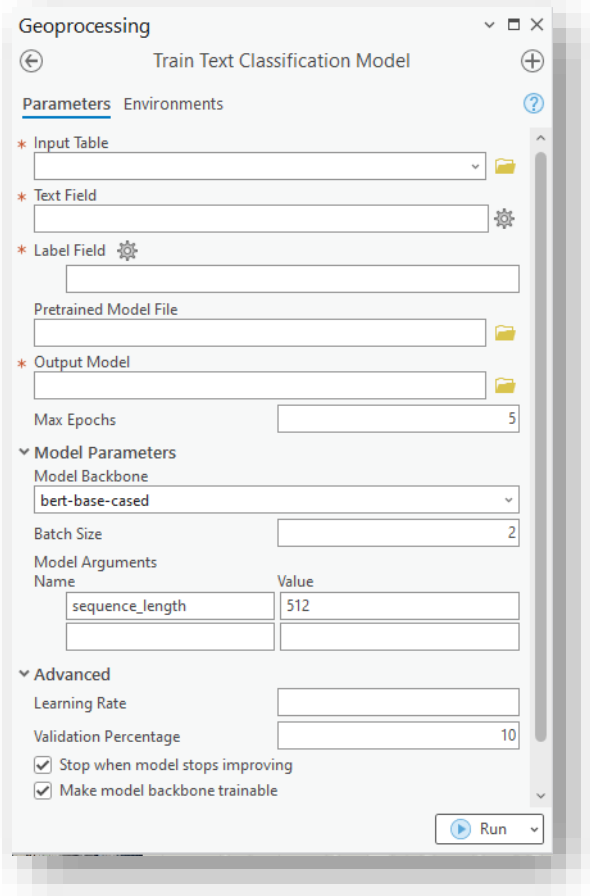
التنبؤ بالبلد الذي ينتمي إليه العنوان غير المكتمل.

نماذج تصنيف النص في ArcGIS عبارة عن شبكات عصبية عميقة تحتوي على مكونين:

• أداة التشفير




• المصنف



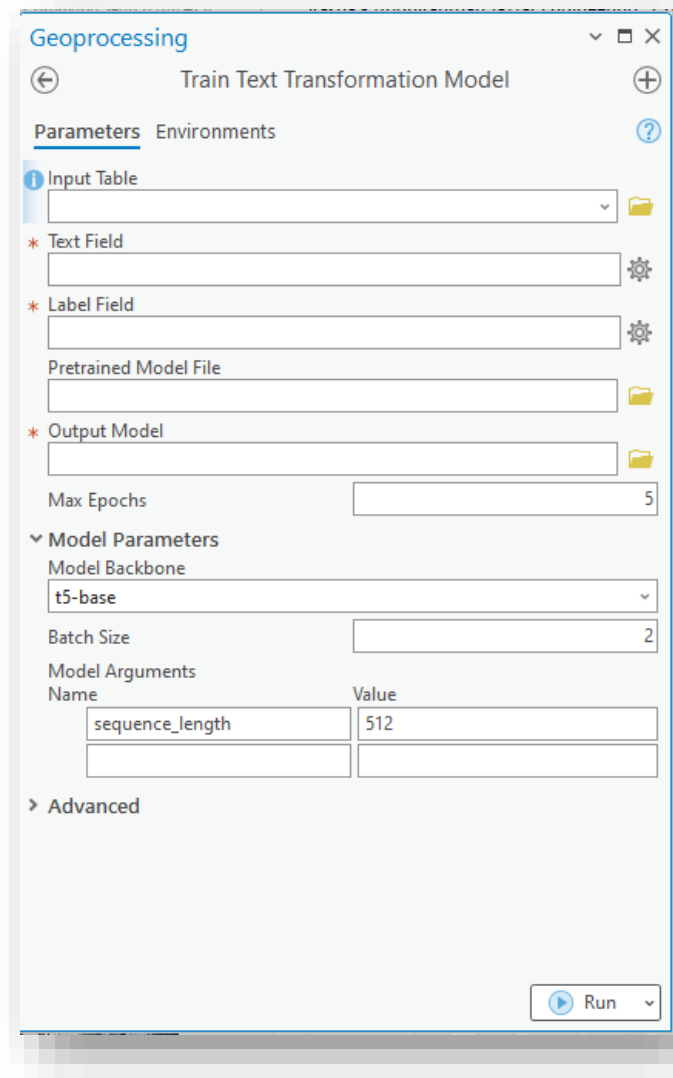
Input: الجدول أو feature class المطلوب تدريب النموذج عليه
 Text Field: حقل نصي في feature class أو الجدول الذي يحتوي على النص الذي سيتم تصنيفه حسب النموذج.
 Label Field: حقل نصي يحتوي على تسميات الفئة المستهدفة لتدريب النموذج. في حالة تصنيف النص متعدد العناوين، يتم تحديد أكثر من حقل نصي.
 Pretrained Model File: نموذج تم تدريبه مسبقًا والذي سيتم استخدامه لضبط النموذج الجديد؛ يجب أن يتم تدريب النموذج المُدرَّب مسبقًا بنفس نوع النموذج والنموذج الأساسي الذي سيتم استخدامه لتدريب النموذج الجديد.
 Model Backbone: يحدد الشبكة العصبية المكونة مسبقًا والتي ستكون بمثابة أداة التشفير للنموذج واستخراج تمثيلات الميزات لنص الإدخال في شكل متجهات ذات طول ثابت.

أداة Train Text Transformation Model

تقوم بتدريب نموذج تحويل النص على تحويل النصوص أو ترجمتها أو تلخيصها.

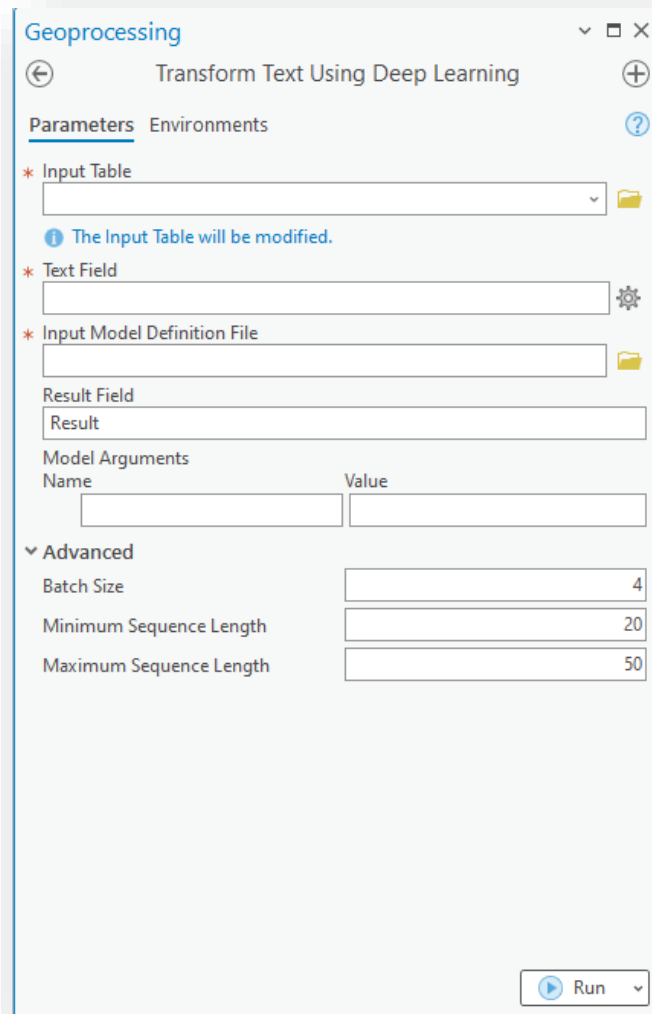


يمكن لنموذج تحويل النص تصحيح الأخطاء الإملائية وتوحيد عناوين الشوارع.




أداة Transform Text Using Deep Learning:

تستخدم لتشغيل نموذج تسلسل إلى تسلسل مُدرّب في حقل نص في feature class أو جدول وتحديثه بحقل جديد يحتوي على النص المحول أو المترجم.



مجموعة أدوات Time Series AI :



أداة : Forecast Using Time Series Model

يتنبأ بقيم كل موقع الزمكان باستخدام نموذج تنبؤ بالسلاسل الزمنية قائم على التعلم العميق والذي تم تدريبه باستخدام

أداة. Train Time Series Forecasting Model.

تستخدم هذه الأداة نماذج التنبؤ بالسلاسل الزمنية القائمة على التعلم العميق. تتمتع نماذج التعلم العميق بقدرة عالية على التعلم وهي مناسبة للسلاسل الزمنية التي تتبع اتجاهات معقدة ويصعب تصميمها باستخدام وظائف رياضية بسيطة.

ومع ذلك، فإنها تتطلب حجمًا أكبر من بيانات التدريب لتعلم مثل هذه الاتجاهات المعقدة واستخدام المزيد من الموارد

الحسابية للتدريب والاستدلال.

يمكن استخدام Outlier Option للكشف عن القيم المتطرفة ذات الأهمية الإحصائية في قيم السلاسل الزمنية في كل موقع.

Input Time Series Data :مكعب netCDF الذي يحتوي على المتغير الذي سيتم

استخدامه للتنبؤ بالخطوات الزمنية المستقبلية. يجب أن يحتوي هذا الملف على

ملحق ملف nc. ويجب أن يكون قد تم إنشاؤه باستخدام أداة إنشاء Space

.Time Cube

Model Definition : ملف نموذج التعلم العميق المدرب (dlpk. أو . emd)

الذي سيتم استخدامه لإجراء التنبؤات. يمكن تدريب النموذج باستخدام أداة

نموذج التنبؤ بالسلسلة الزمنية.

Output Cupe : ملف . nc يحتوي على قيم مكعب الزمكان المدخل مع الخطوات

الزمنية المتوقعة الملحقة به. ويمكن استخدام أداة Visualize Space Time Cube

في صورة ثلاثية الأبعاد لرؤية جميع القيم المرصودة والمتوقعة في وقت واحد.

Geoprocessing

Forecast Using Time Series Model

Parameters Environments

* Input Time Series Data

* Model Definition

* Output Features

Output Cube

Number of Time Steps to Forecast 2

Match Explanatory Variables Prediction Training

Outlier Option None

Run

أداة Train Time Series Forecasting Model :

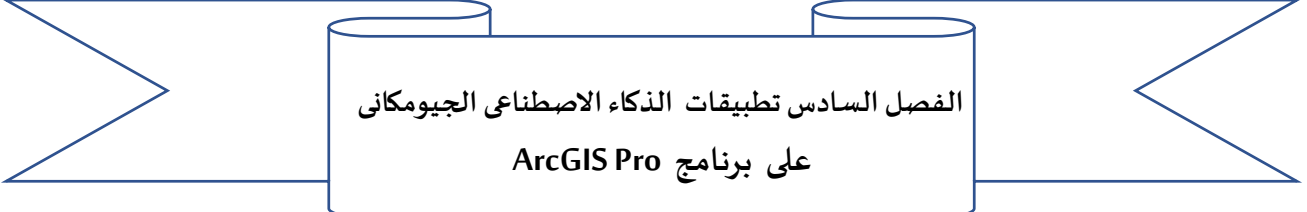
تقوم هذه الأداة بتدريب نماذج التنبؤ بالسلاسل الزمنية باستخدام نماذج مختلفة قائمة على التعلم العميق، مثل الشبكة المتصلة بالكامل ((FCN، والذاكرة الطويلة قصيرة المدى (LSTM، و InceptionTime، و ResNet، و ResCNN) ؛ تدعم هذه النماذج السلاسل الزمنية متعددة المتغيرات، حيث يتعلم النموذج من أكثر من متغير تابع للوقت للتنبؤ بالقيم المستقبلية. يتم حفظ النموذج المُدرَّب كملف حزمة التعلم العميق (.dlpk) ويمكن استخدامه للتنبؤ بالقيم المستقبلية باستخدام أداة

Forecast Using Time Series Model

The screenshot shows the 'Train Time Series Forecasting Model' tool in the Geoprocessing environment. The tool is currently in the 'Parameters' tab. The following parameters are visible:

- Input Time Series Data:** Empty text field.
- Output Model:** Empty text field.
- Analysis Variable:** Empty text field.
- Sequence Length:** Empty text field.
- Explanatory Training Variables:** A dropdown menu labeled 'Variables' and a checkbox labeled 'Categorical'.
- Max Epochs:** Text field containing the value '20'.
- Number Of Time Steps to Exclude for Validation:** Empty text field.
- Model Parameters:**
 - Model Type:** Dropdown menu set to 'InceptionTime'.
 - Batch Size:** Text field containing the value '64'.
 - Model Arguments:** A table with two columns: 'Name' and 'Value'. Both fields are currently empty.
- Stop training when model no longer improves:** Checked checkbox.
- Additional Output:**
 - Output Feature Class:** Empty text field.
 - Output Cube:** Empty text field.

A 'Run' button is located at the bottom right of the tool interface.



الفصل السادس تطبيقات الذكاء الاصطناعي الجيومكاني
على برنامج ArcGIS Pro

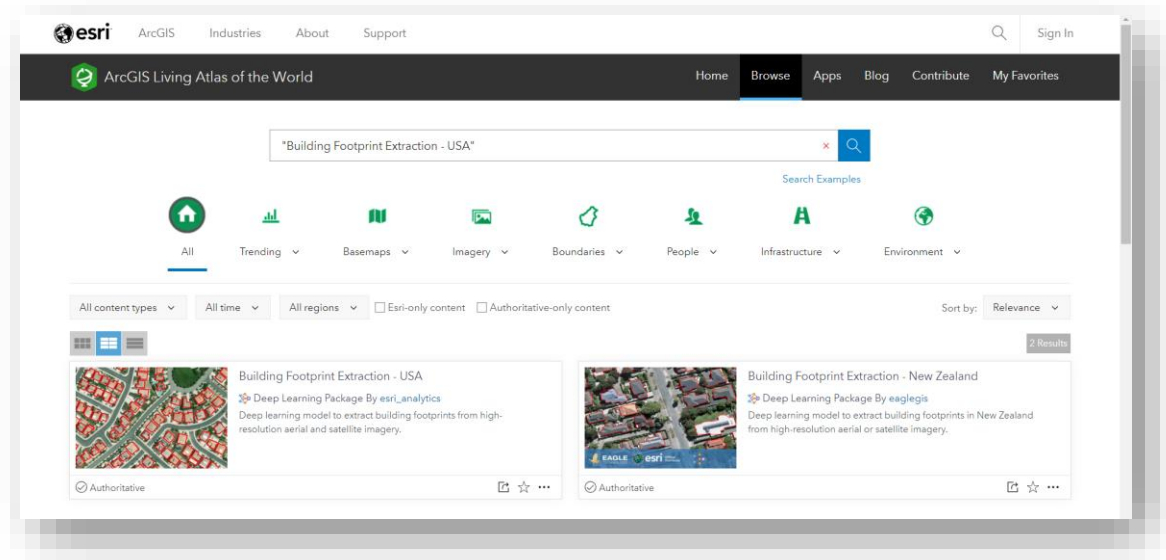
أمثلة تطبيقية :

1- استخراج المباني من الصور الفضائية

الحصول على بعض النماذج

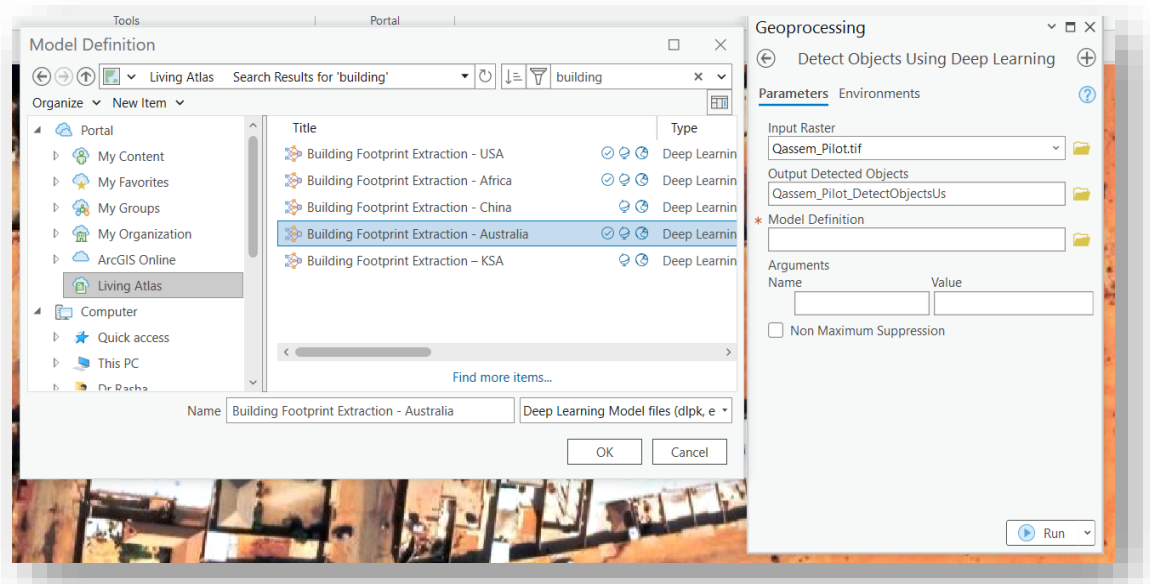
<https://livingatlas.arcgis.com/en/browse/#d=2>

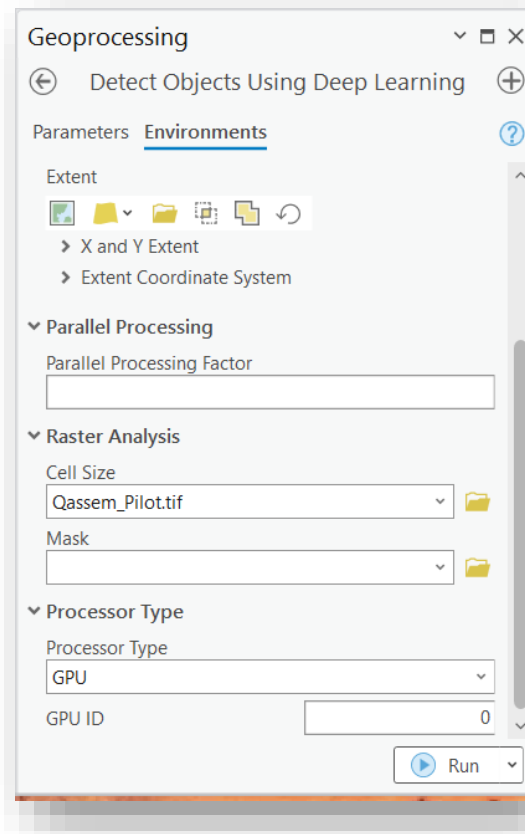
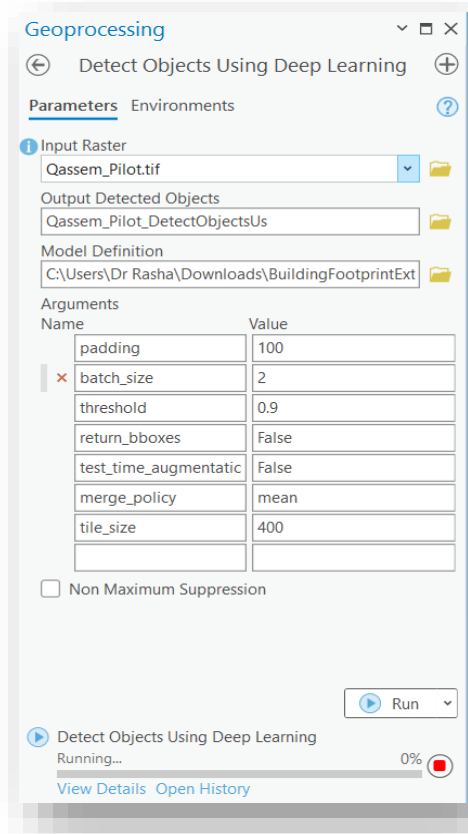
- يتم اختيار Building Footprint



- بعد ذلك يتم عمل تحميل للنموذج على الجهاز ؛ ويمكن استعداؤه مباشرة من الاداة التالية

- يتم استخدام أداة Detect Objects Using Deep Learning

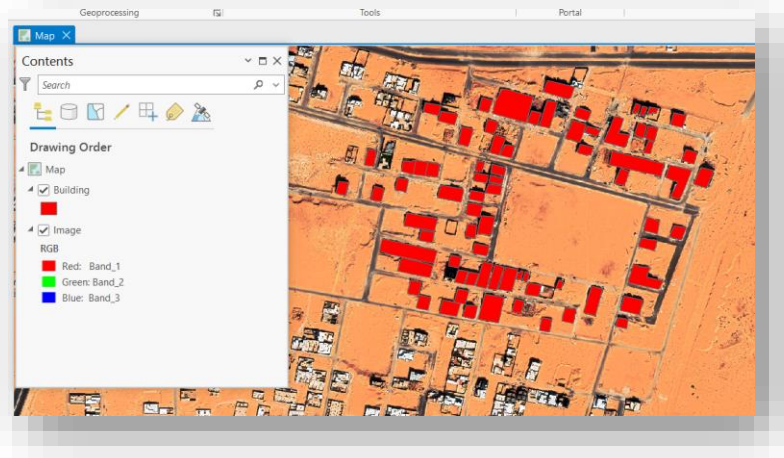




قد يكون النموذج المستخدم لا يتناسب مع منطقة العمل ؛ لذا نلجأ الى تدريب نموذج بأنفسنا ؛ وهذا يستدعى الحصول على بيانات تدريبية أولا ويمكن القيام بذلك على النحو الموضح أدناه :

استخراج بيانات للتدريب: مثال استخراج المباني

1- يتم رسم مجموعة من المباني كعينة للتدريب (يتم مراعاة اختيار عينة التدريب على مباني مختلفة من حيث هندستها " شكلها").



2- يتم انشاء حقلين حقل للاسم ويتم ادخال اسم الصنف وهنا يكون (Building) وحقل القيمة و ادخال قيمة موحدة داخل جدول البيانات الوصفية كقيمة الصنف Value ولتكون 1 ؛ واذا تم اخذ عينات لاكثر من صنف يعطى لكل صنف قيمة .

Building - MyProject5 - ArcGIS Pro

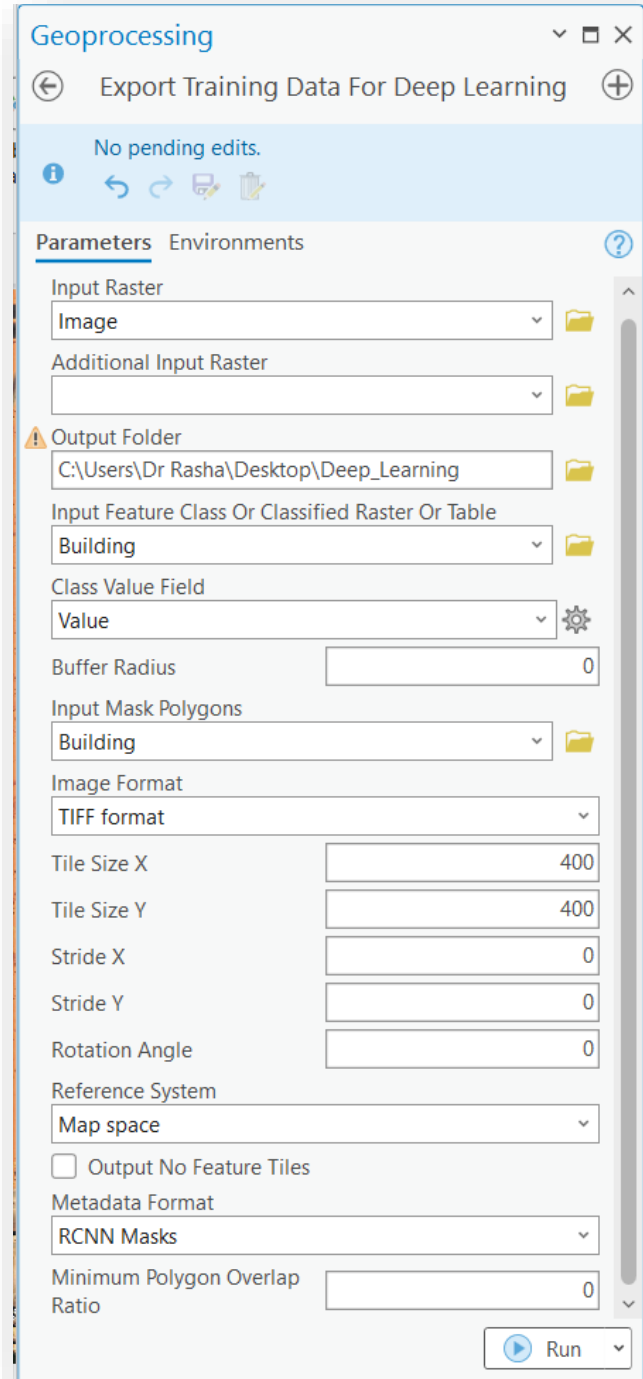
Building

Field: Selection:

OBJECTID *	SHAPE *	Shape_Length	Shape_Area	Value	Name
1	Polygon Z	0.000931	0	1	Building
2	Polygon Z	0.000872	0	1	Building
3	Polygon Z	0.00098	0	1	Building
4	Polygon Z	0.000897	0	1	Building
5	Polygon Z	0.000974	0	1	Building
6	Polygon Z	0.000705	0	1	Building
7	Polygon Z	0.001097	0	1	Building
8	Polygon Z	0.001344	0	1	Building
9	Polygon Z	0.000929	0	1	Building
10	Polygon Z	0.001498	0	1	Building
11	Polygon Z	0.001007	0	1	Building
12	Polygon Z	0.000992	0	1	Building
13	Polygon Z	0.001808	0	1	Building
14	Polygon Z	0.002809	0	1	Building
15	Polygon Z	0.001883	0	1	Building
16	Polygon Z	0.001032	0	1	Building
17	Polygon Z	0.001036	0	1	Building
18	Polygon Z	0.000877	0	1	Building

0 of 77 selected Filters:

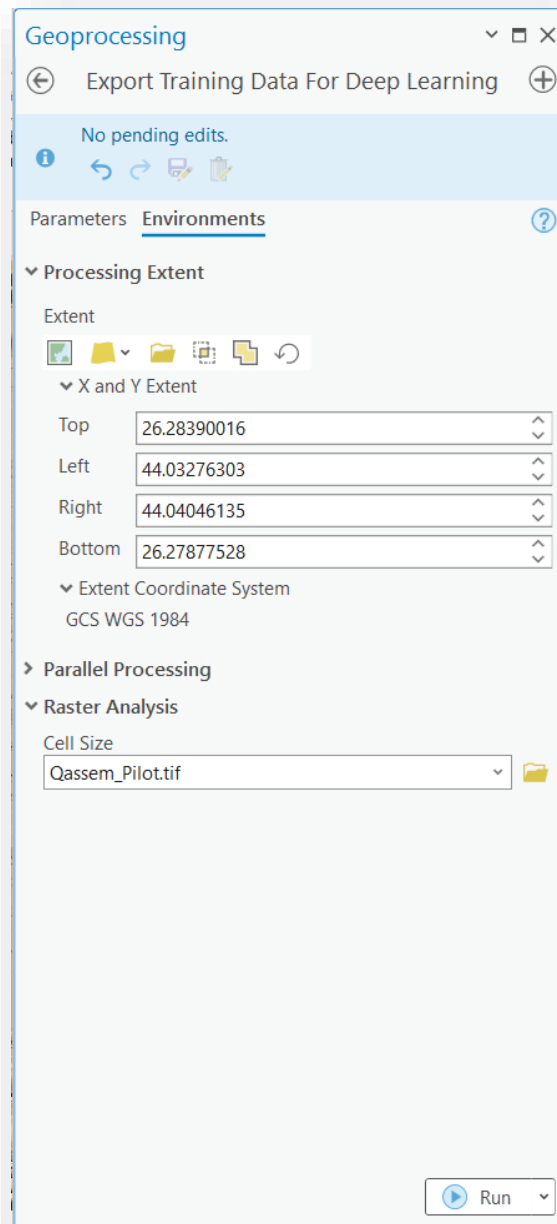
استخدام أداة Export Training Data For Deep Learning



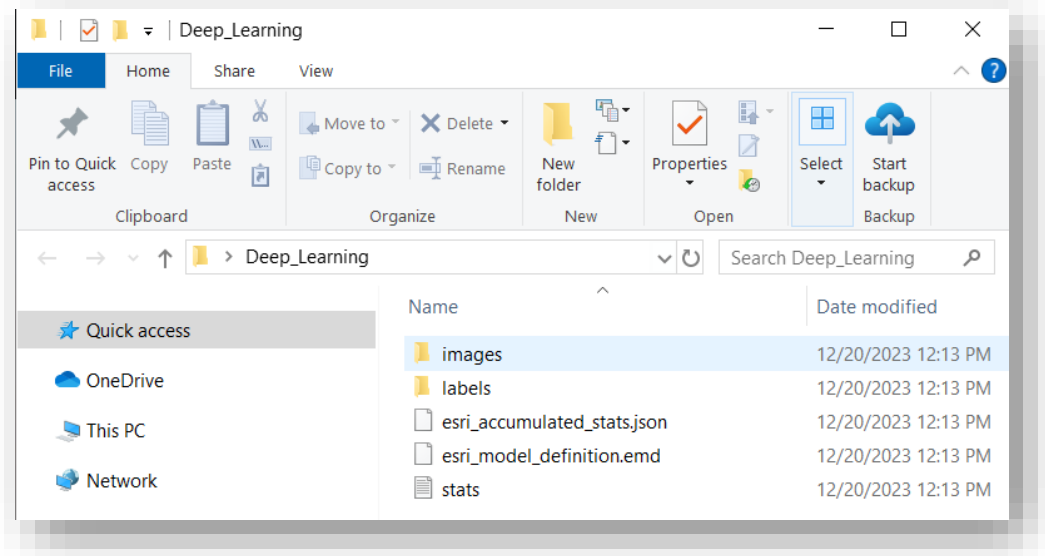
حجم الصورة

التداخل في الصور

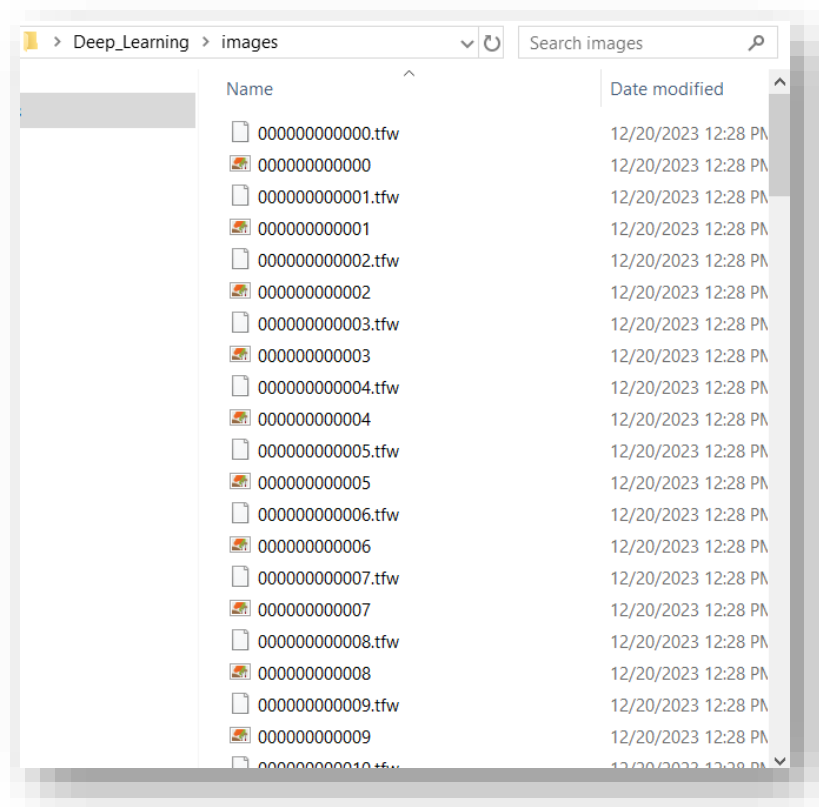
نوع البيانات الوصفية RCNN



النتائج من الاداة



ملف به الصور التي تم اخذها كعينة



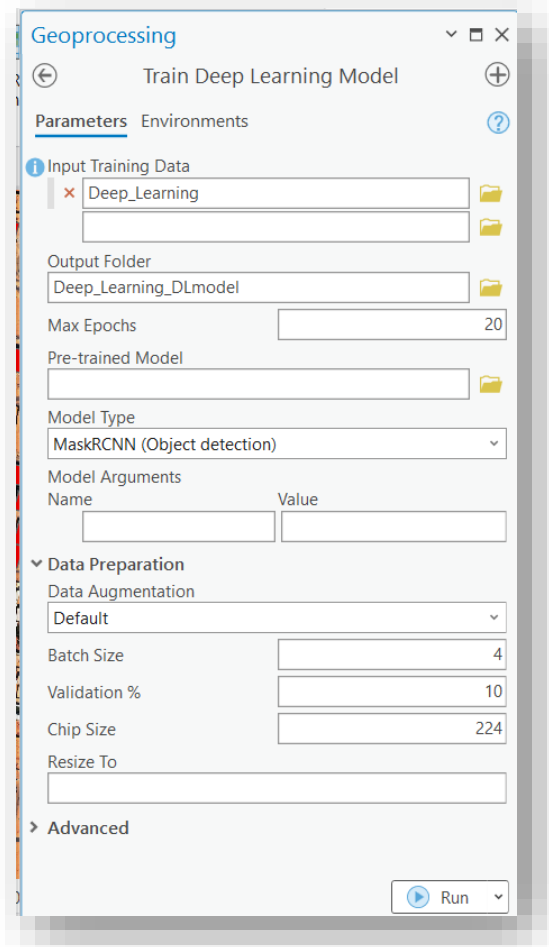
ملف مسميات الصور:

ملف الاحصاء عن العينات التي تم اخذها عددها ؛ قيمتها

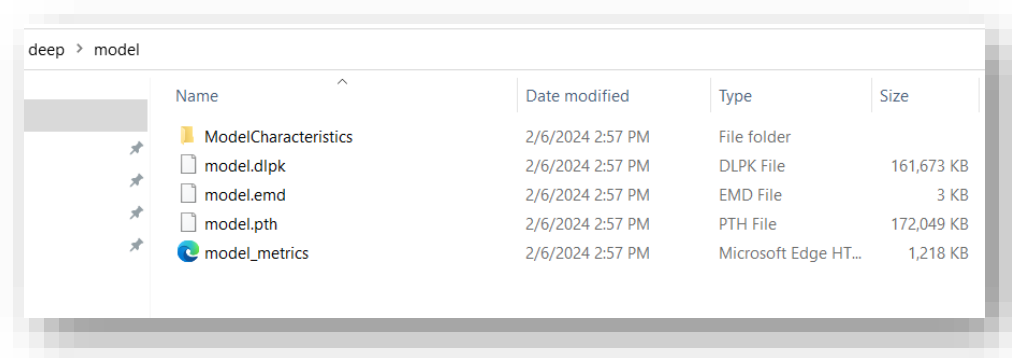
```
stats - Notepad
File Edit Format View Help
images = 66 *3*256*256

Class feature statistics:]
features = 164
features per image = [min = 1, mean = 2.48, max = 6]
classes = 1
cls name          cls value  images  features  min size  mean size  max size
1                  1         66     164       0.00     0.00     0.00
```

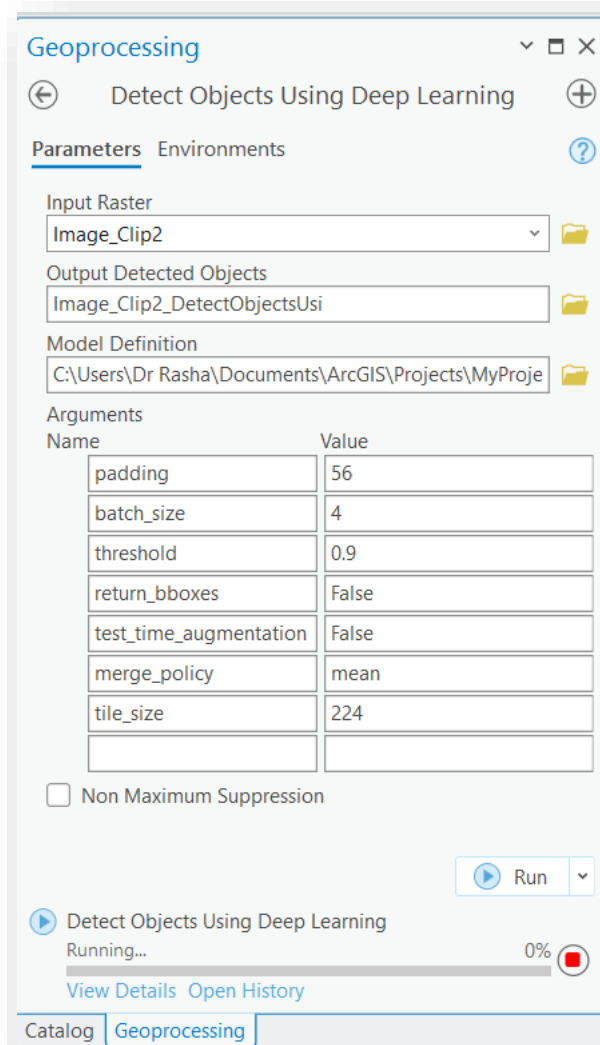
تدريب النموذج



النتائج من الأداة:

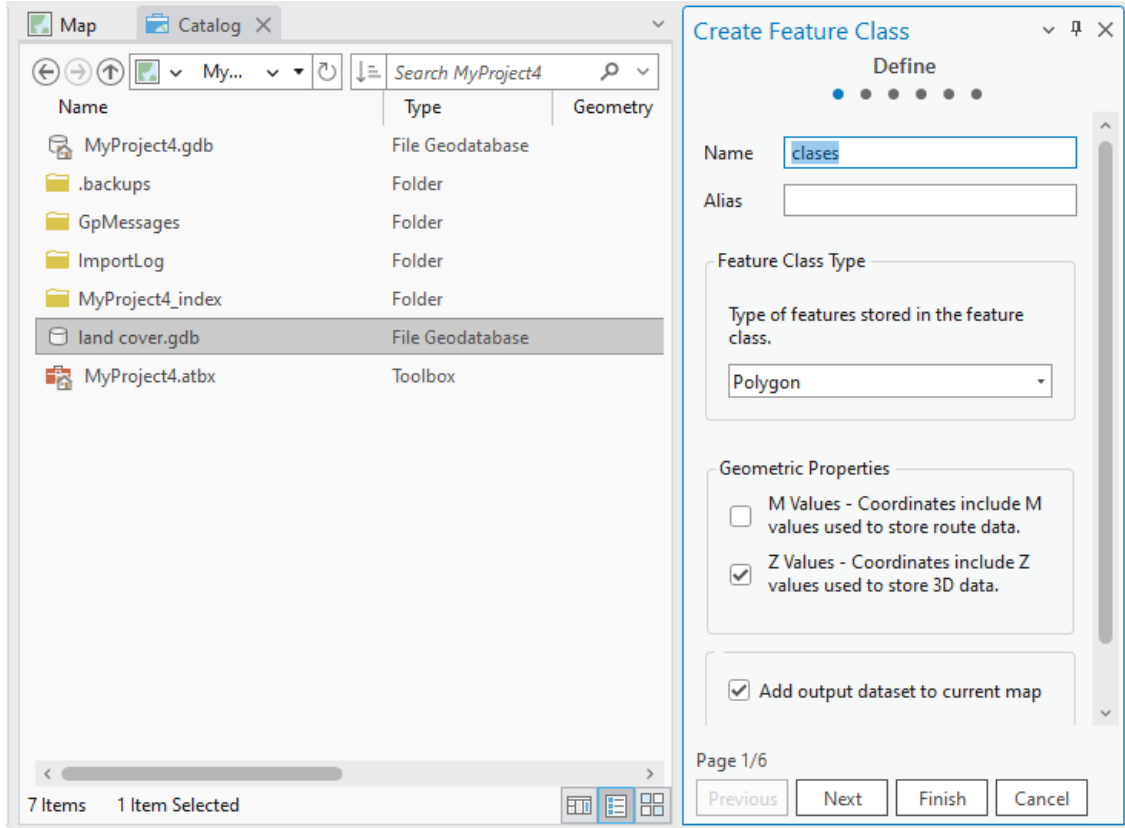


بعد ذلك يتم استخدام أداة Detect Objects Using Deep Learning



2- رسم خرائط الغطاء الأرضي باستخدام صورة جوية عالية الدقة (الدرونز):

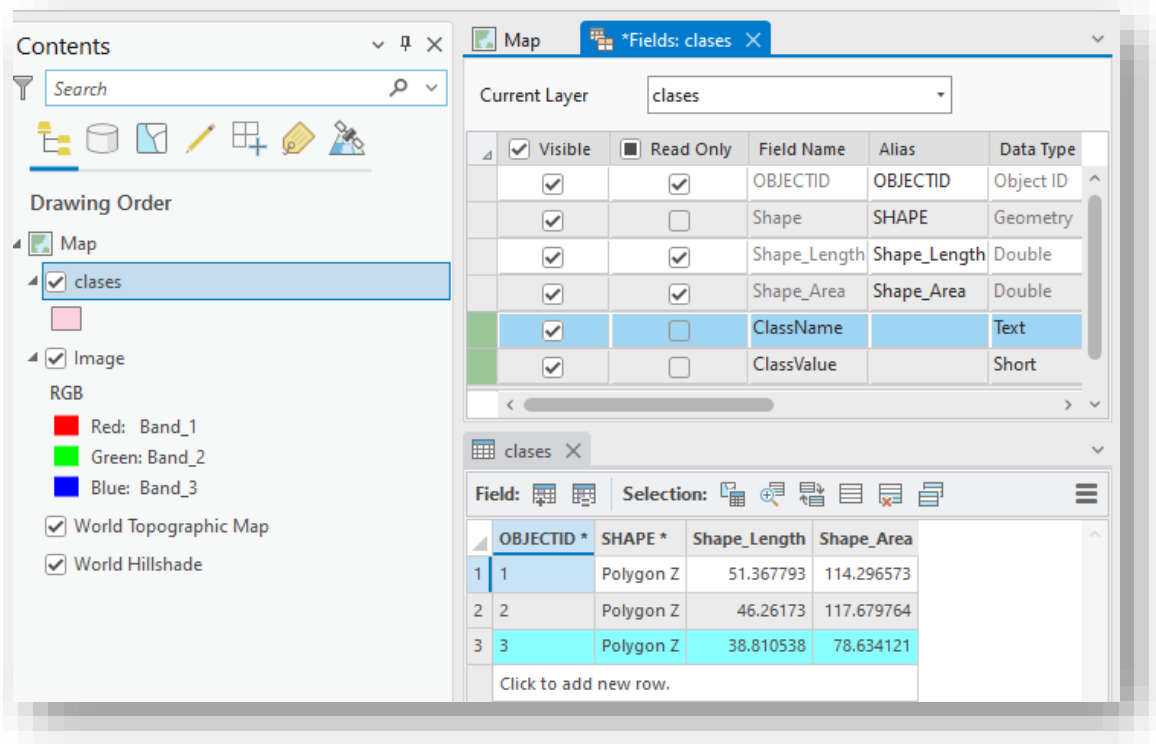
يتم انشاء Feature Class لاستخراج بيانات التدريب



يتم اخذ عينات من الصورة للتدريب (تم اختيار الطرق – المباني – الاراضى البيضاء)



انشاء حقلين داخل جدول البيانات الوصفية واحد من نوع النصى لاسم الصنف واخر من النوع الرقى لقيمة الصنف



حيث يتم تسمية الاصناف مع اعطاء قيمة لكل صنف وذلك على النحو التالي :

Value	Name
1	Road
2	Build
3	Space

classes - MyProject4 - ArcGIS Pro

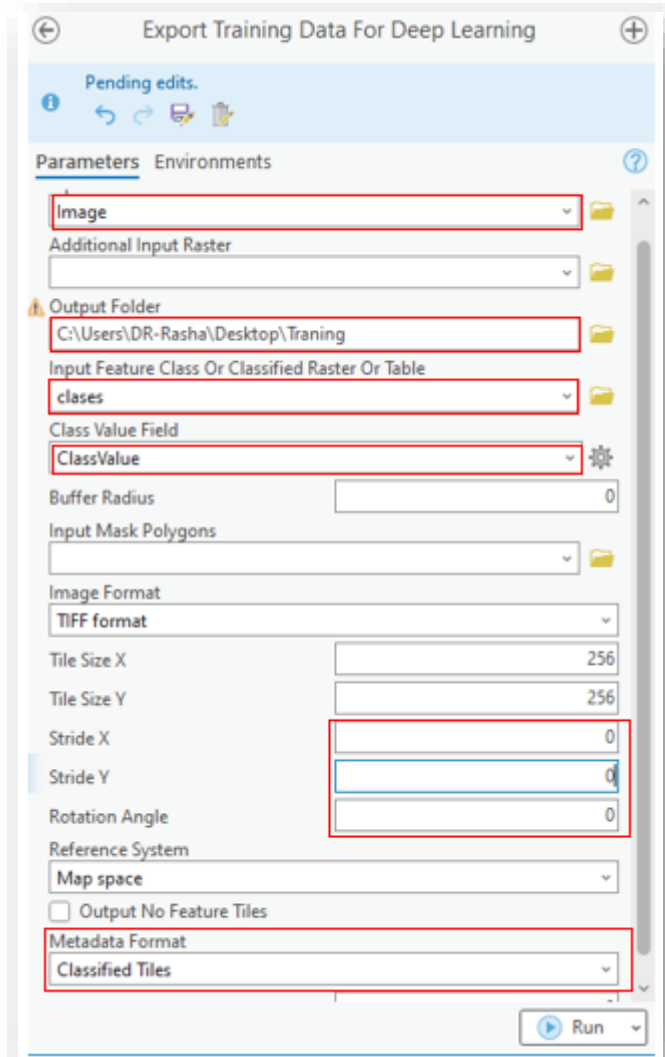
classes X

Field: Add Calculate Selection: Select By Attributes Zoom To Switch

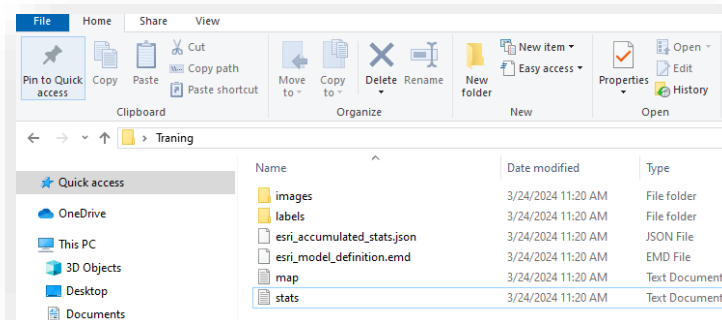
	OBJECTID *	SHAPE *	Shape_Length	Shape_Area	ClassName	ClassValue
5	5	Polygon Z	41.911014	91.819638	road	1
6	6	Polygon Z	37.737155	85.329121	road	1
7	7	Polygon Z	34.9914	52.130071	road	1
8	8	Polygon Z	23.953636	33.165773	road	1
9	9	Polygon Z	36.221659	54.193149	road	1
10	10	Polygon Z	18.972843	19.723164	road	1
11	11	Polygon Z	20.276034	21.090624	road	1
12	12	Polygon Z	18.607886	20.288045	road	1
13	13	Polygon Z	19.107319	22.120455	road	1
14	14	Polygon Z	13.427416	11.126013	road	1
15	15	Polygon Z	49.996539	99.15637	road	1
16	16	Polygon Z	51.952803	140.072958	road	1
17	17	Polygon Z	45.265971	121.795565	road	1
18	18	Polygon Z	68.227116	288.226112	Build	2
19	19	Polygon Z	107.589307	499.097906	Build	2
20	20	Polygon Z	78.907427	346.977578	Build	2
21	21	Polygon Z	55.271877	132.681356	Build	2
22	22	Polygon Z	52.085543	165.613579	Build	2
23	23	Polygon Z	57.234176	166.501079	Build	2
24	24	Polygon Z	82.503983	388.240343	Build	2
25	25	Polygon Z	37.636158	68.697735	spce	3
26	26	Polygon Z	19.352093	21.658315	spce	3
27	27	Polygon Z	18.826258	21.316826	spce	3
28	28	Polygon Z	16.477194	16.294994	spce	3

بعد ذلك يتم استخدام أداة Export Training Data For Deep Learning

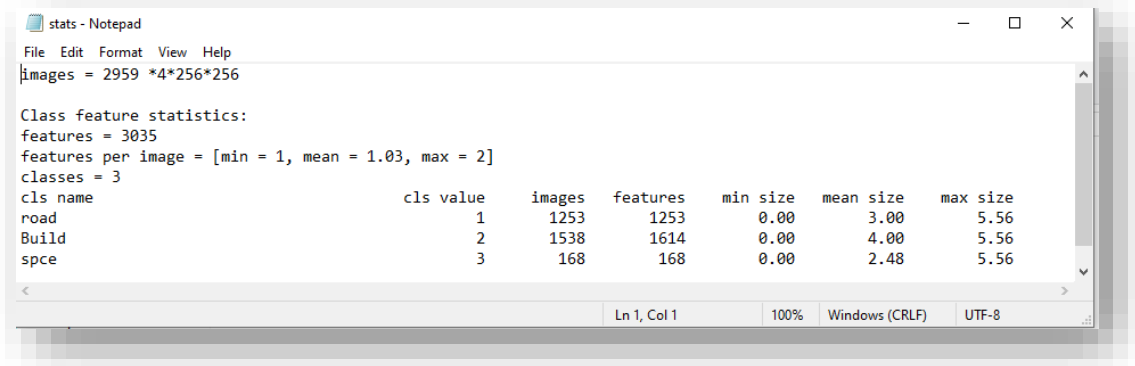
يتم ادخال الصورة الجوية ؛ وبعد ذلك اختيار Feature Class واختيار حقل Class Value وبعد ذلك ضبط نسبة الادخال (0) Strid x,y وكذلك Rotation Angle وأخيرا اختيار الخوارزمية المناسبة (Classified Tiles)



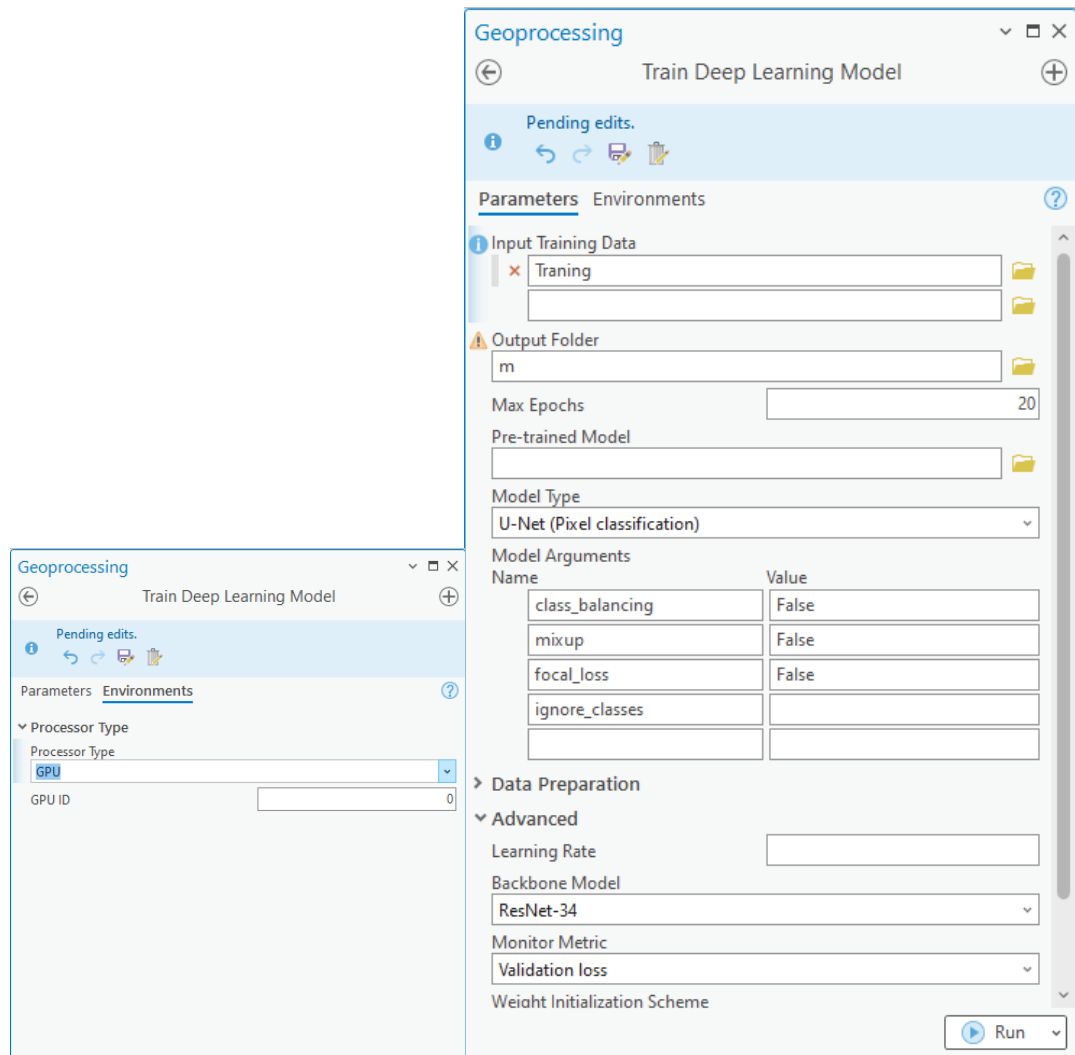
بفتح مجلد النتائج نجد الملفات التالية



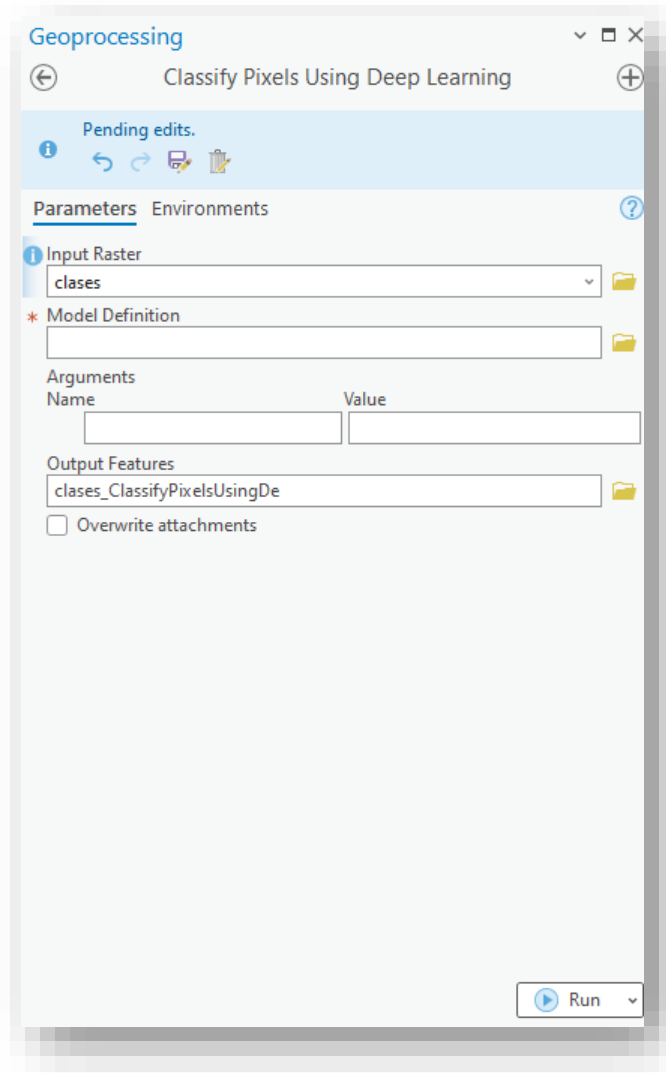
بفتح ملف Stats نجد يحتوى على الثلاثة تصنيفات



بعد ذلك يتم استخدام أداة Train deep learn model



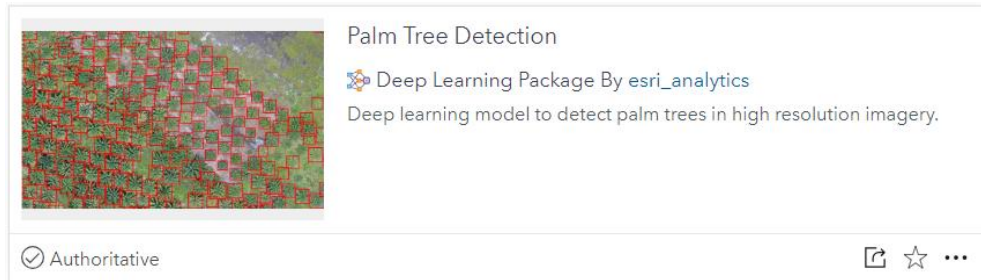
بعد ذلك يتم التصنيف من خلال اداة Classify Pixels Using Deep Learning : حيث يتم الصورة المطلوب عمل تصنيف لها وايضاة النموذج ومن Environment يتم اختيار GPR



3- استخراج النخيل باستخدام المرئيات الفضائية :

وذلك باستخدام نموذج Palm Tree Detection : ويُستخدم للكشف عن أشجار النخيل في الصور الجوية والفضائية. يمكن استخدام الكشف عن أشجار النخيل لإنشاء جرد لأشجار النخيل، ومراقبة صحتها وموقعها، والتنبؤ بإنتاج زيت النخيل، وما إلى ذلك.

- يتم عمل تحميل للنموذج على الجهاز كما تم شرحه سابقا
- يتم استخدام نموذج Palm Tree Detection من موقع Living Atlas.



- يتم استخدام أداة Detect Objects Using Deep Learning لإستدعاء النموذج والعمل عليه بنفس طريقه عمل الأمثلة السابقة ثم عمل Run.

OBJECTID*	SHAPE*	Shape_Length	Shape_Area	Class_Name	Class_Value
1	Polygon Z	30.397168	57.74924	Palm	1
2	Polygon Z	30.526547	58.24188	Palm	1
3	Polygon Z	32.725155	66.933487	Palm	1
4	Polygon Z	26.18696	42.859806	Palm	1

4- تحديد صحة النخيل :

بعد استخراج النخيل في التطبيق السابق يمكننا قياس صحة النخيل من المرئيات الفضائية من خلال استخدام الأطياف المرئية في الصور حيث يقوم مؤشر (CLG) بتقدير كمية الكلوروفيل الموجودة في الغطاء النباتي بناءً على النسبة بين انعكاس الأشعة تحت الحمراء القريبة (NIR) والنطاق الأخضر، تشير القيم المنخفضة للكلوروفيل إلى انخفاض قوة الغطاء النباتي ويمكن أن تساعدنا في تحديد أشجار النخيل التي تحتاج إلى علاج.

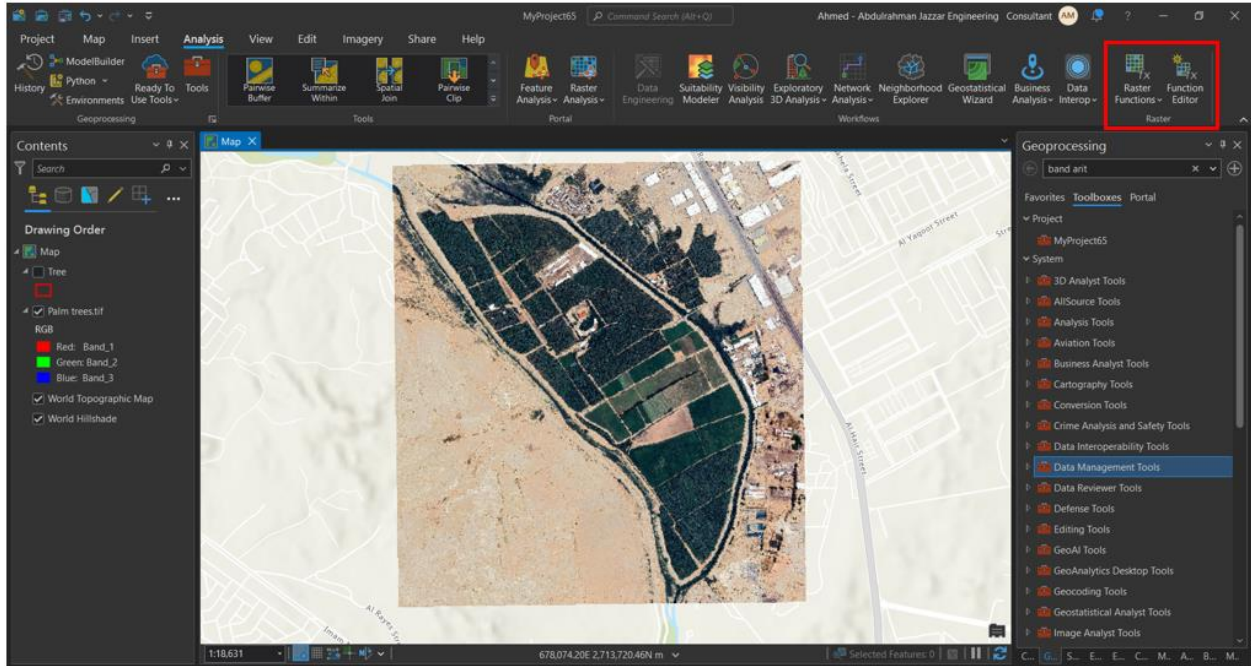
طريقة حساب المؤشر : $CLG = [(NIR / Green) - 1]$

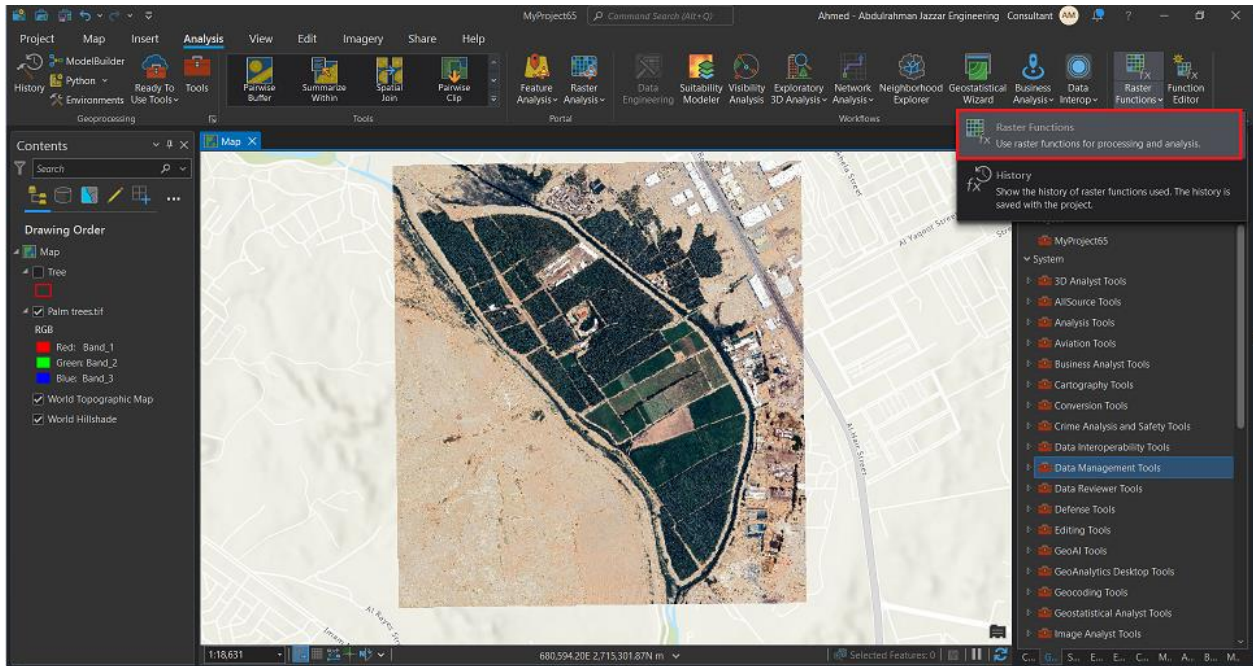
NIR = نطاق الأشعة تحت الحمراء القريبة

Green = قيم البكسل من النطاق الأخضر

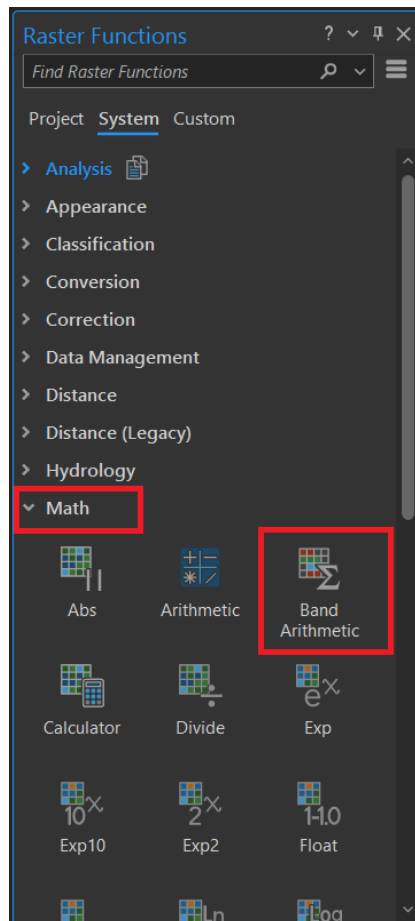
ويمكن تطبيق ذلك على النحو الموضح أدناه:

- إختيار Raster Functions من قائمة Raster Analysis.

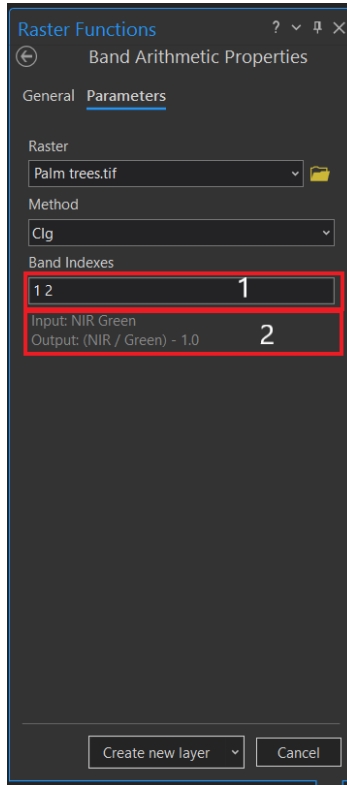




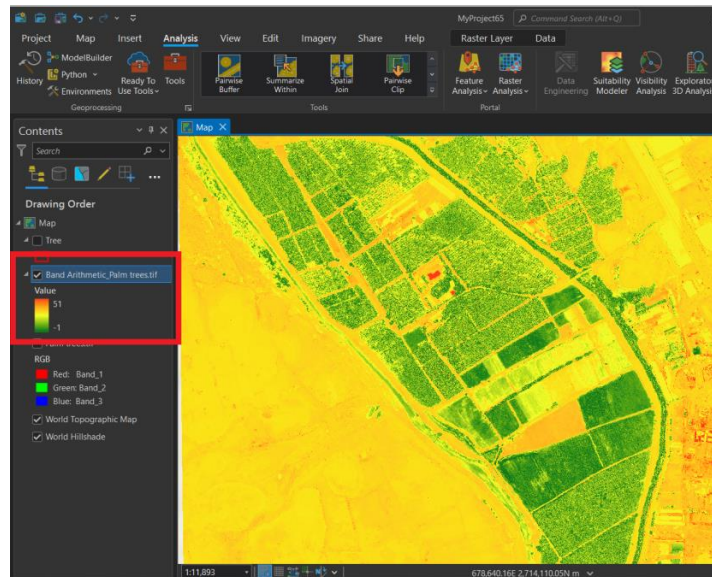
• إختيار قائمة Math ثم إختيار Band Arithmetic.



- بعد إختيار الصورة المطلوبة والمؤشر المراد العمل عليه Clg يتم إدخال البندات المطلوبة (حسب المرئية المستخدمة).

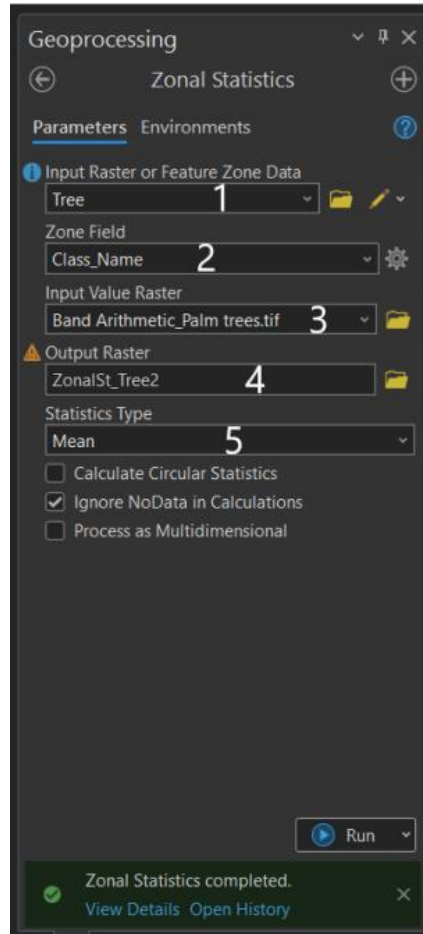


- تظهر ناتج العملية كما موضح حيث يشير اللون الأخضر الداكن إلى نسبة أعلى من الغطاء النباتي، ويشير اللون البرتقالي إلى نسبة منخفضة من الغطاء النباتي.




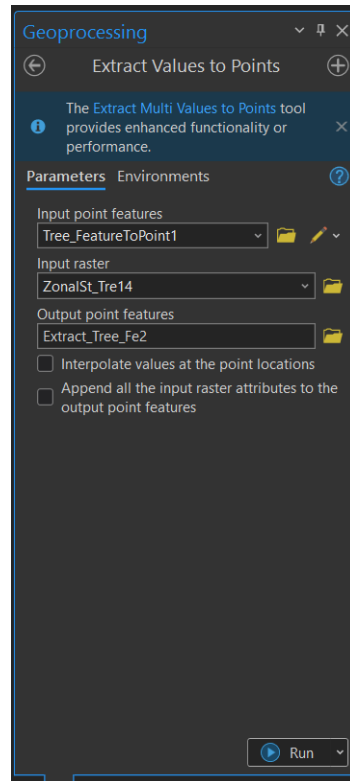
- استخدام أداة Zonal Statistics ليصبح لدينا بيانات نقطية لعرض متوسط قيمة CLG بالبيكسل فوق كل نخلة تم تحديدها، حيث تم تغطية مخرجات CLG الجديدة بالمضلعات التي تم إنشاؤها من أداة اكتشاف الكائنات باستخدام أداة التعلم العميق (عند استخراج النخيل في النموذج السابق).

حيث أن بالنقطة رقم 1 يتم تحديد طبقة المضلعات، والنقطة رقم 2 الحقل الذي يحتوي على القيم التي تحدد كل منطقة، والنقطة رقم 3 يتم إختيار صورة CLG الجديدة والنقطة رقم 4 لتحديد المخرج، وأما بالنقطة رقم 5 فيتم تحديد نوع الإحصائية التي سيتم حسابها.

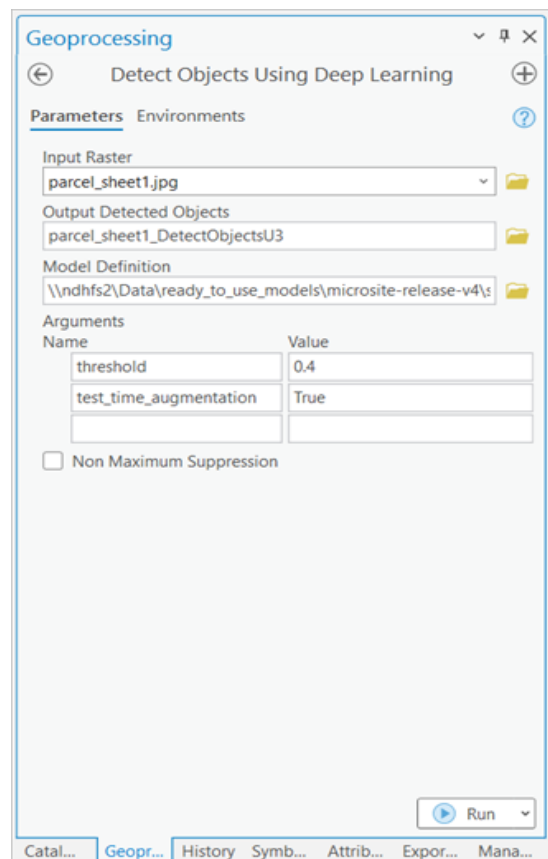
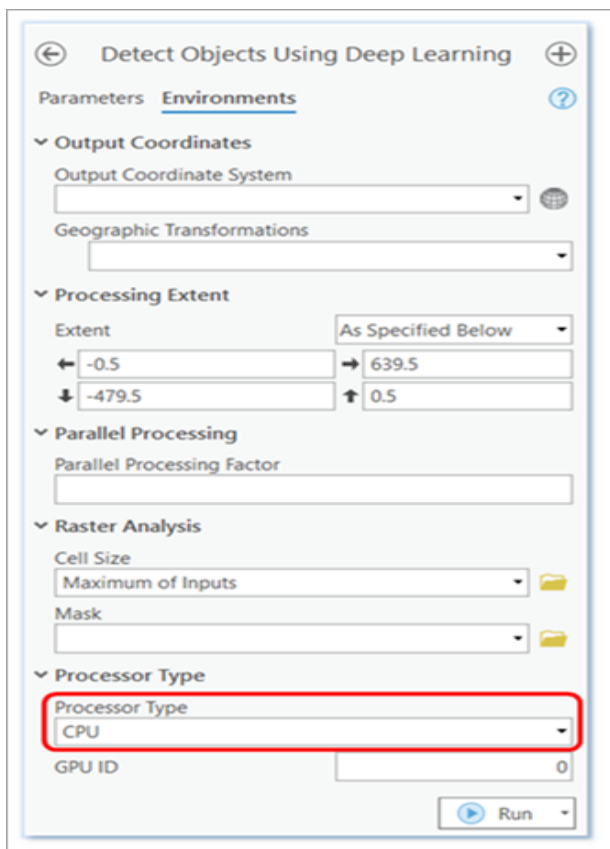
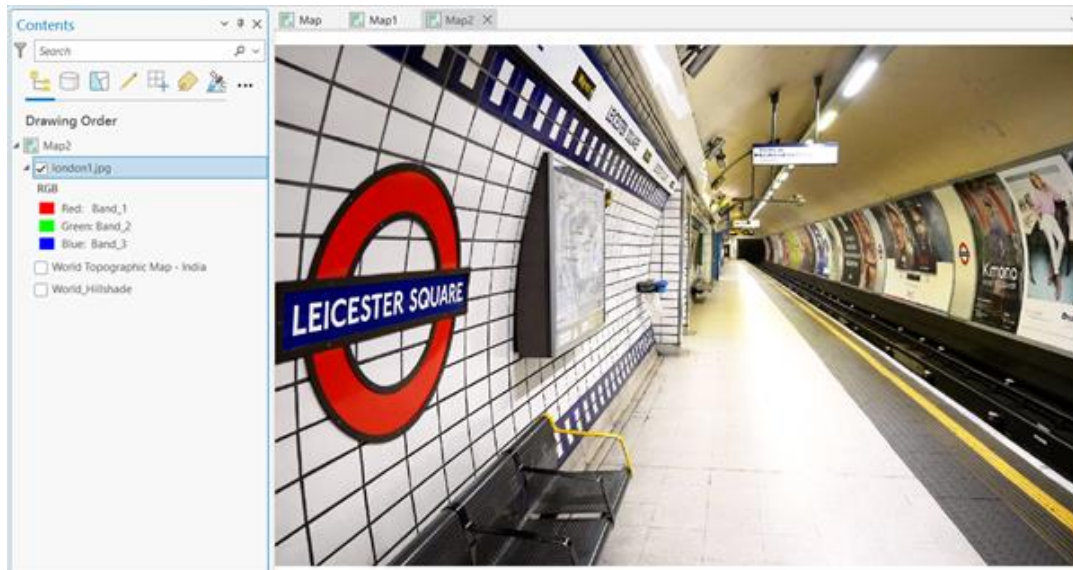


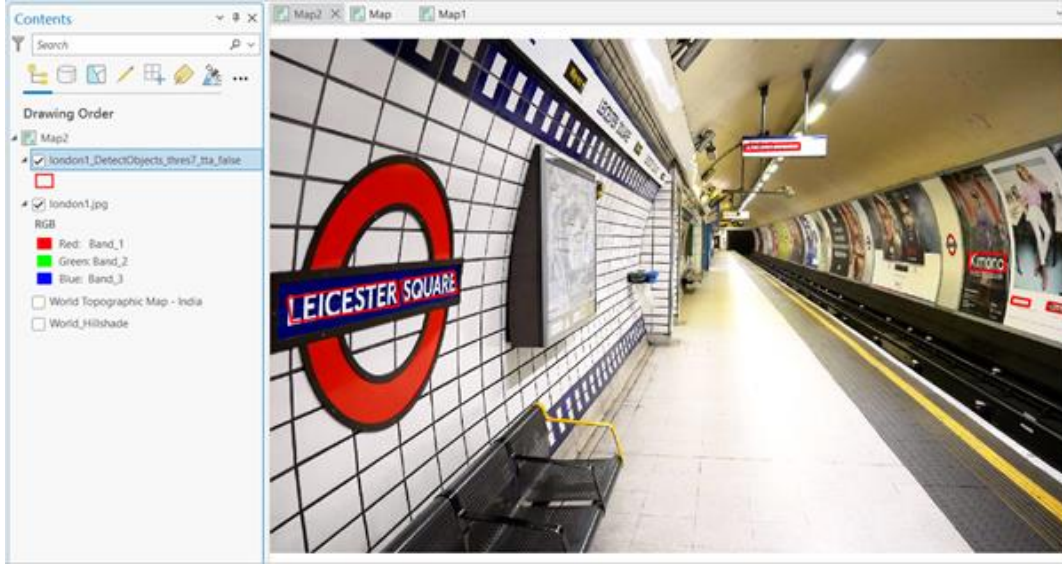
- استخدام أداة المعالجة الجغرافية Feature to Point للحصول على النقطة الوسطى لكل مضلع لتسهيل تفسير المخرجات.

- بعد ذلك يتم استخدام أداة Extract Values to Points لاستخراج المخرجات الإحصائية إلى طبقة النقاط، و ترميزها وفقًا لقيمة CLG الخاصة بها.



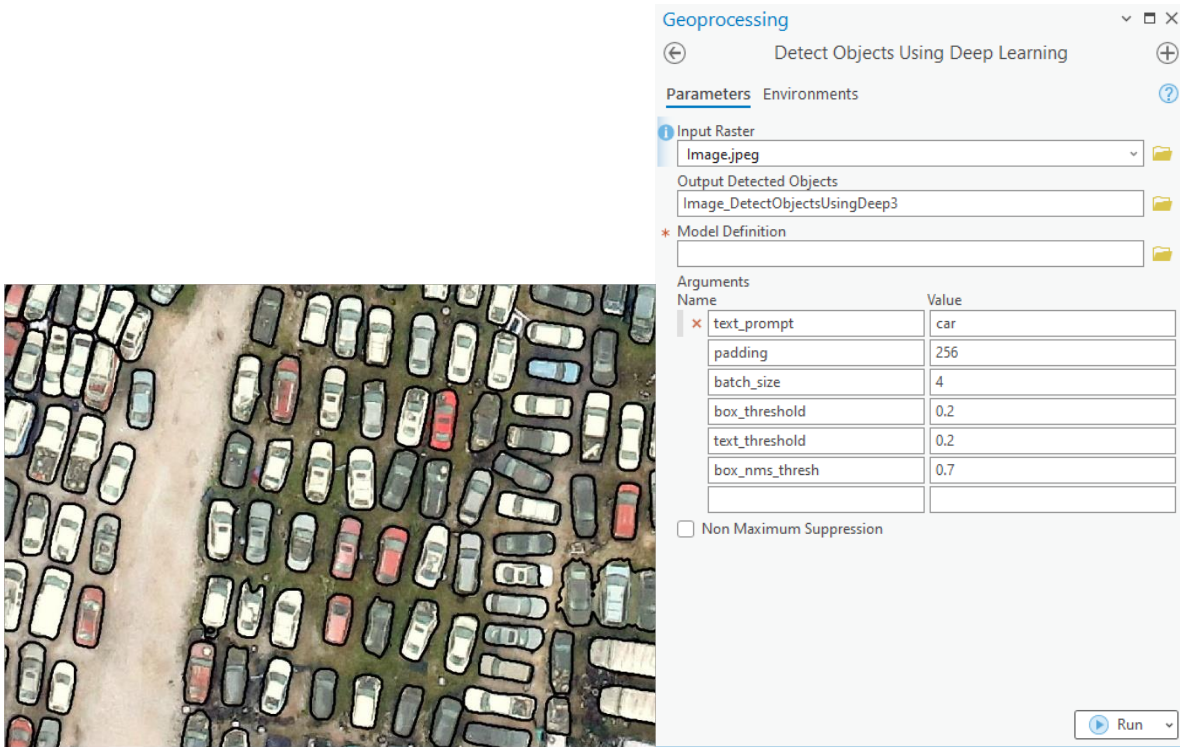
هناك مجموعة من النماذج الأخرى لاستخراج النصوص مثل نموذج Scene Text Parsing





ونموذج Text SAM و هو نموذج يمكنه استخدام مطالبات نصية ذات شكل حر لاستخراج ميزات من أنواع مختلفة.

ويتم استخدامه لاستخراج الكائنات مثل السيارات – الطائرات عن طريق أداة Detect Object Using Deep learning
 فيكتابة اسم الكائن car داخل Text Prompo يتم استخراجها من الصورة كما موضح أدناه



Address Standardization ونموذج

non_std_address	Result
23 yeerace crescent north east, medicine hat, ca	23 terrace crescent ne, medicine hat, ca
8 cl prieta padornelo, 49574, es	8, cl prieta padornelo, 49574, es
60, chemin de la clôte, lissieu, 69380, fr	60, chemin de la clôte, lissieu, 69380, fr
132ter, rue oluis petit, denain, 59220, fr	132ter, rue louis petit, denain, 59220, fr
19, hofstatt, senftenberg, 3500, at	19, hofstatt, senftenberg, 3500, at
34, molsvej, 6950, dk	34, molsvej, 6950, dk
1, samild dal, st 20, 8800, dk	1, asmild dal, st 20, 8800, dk
10, cl gujarrak, 21668, es	10, cl gujarral, 21668, es
26, cl palmitos, 4130, es	26, cl palmitos, 4130, es
campbellparade, bondi beach, au	campbell parade, bondi beach, au
1a, avenue du moulin vieux, venerque, 31810, fr	1a, avenue du moulin vieux, venerque, 31810, fr
60, cjuan carlos i, 5120, es	60, cl juan carlos i, 5120, es
7a, ag aplmeritas, 21430, es	7a, ag palmeritas, 21430, es

☆ Add to Favorites

Deep Learning model to transform non-standard address to standard address.

 Deep learning package by esri_analytics

Item created: Jul 26, 2022 Item updated: Feb 1, 2024 Number of downloads: 2,517

 Living Atlas

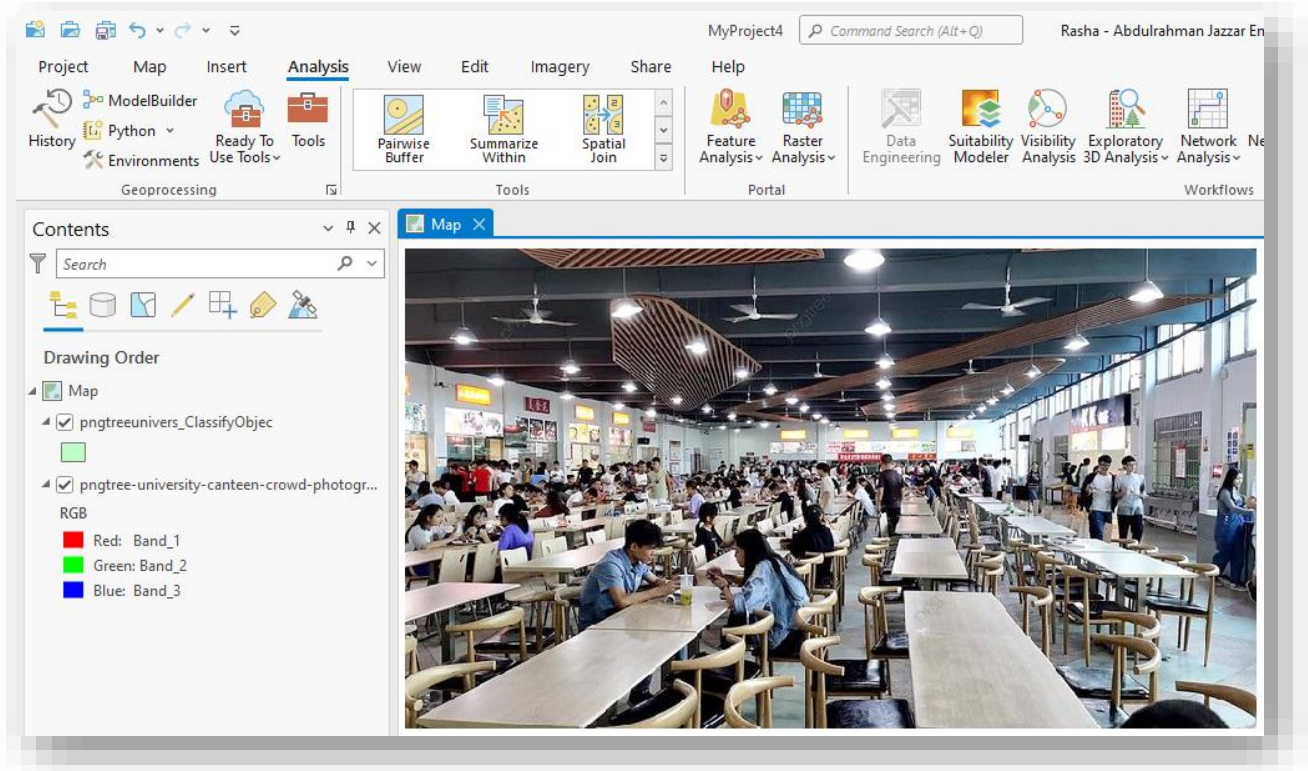
و يستخدم لتوحيد وتنسيق العناوين حيث يتم ادخال طبقة عناوين غير صحيحة أو غير منسقة ويقوم بتعديلها الى عناوين صحيحة كما موضح أدناه.

--	non_std_address	Result
1	23, yeerace crescent north east, medicine hat, ca	23, terrace crescent ne, medicine hat, ca
2	8, cl prieta padornelo, 49574, es	8, cl prieta padornelo, 49574, es
3	60, chemin de la clôte, lissieu, 69380, fr	60, chemin de la clôte, lissieu, 69380, fr
4	132ter, rue oluis petit, denain, 59220, fr	132ter, rue louis petit, denain, 59220, fr
5	19, hofstatt, senftenberg, 3500, at	19, hofstatt, senftenberg, 3500, at
7	34, molsvej, 6950, dk	34, molsvej, 6950, dk
8	1, samild dal, st 20, 8800, dk	1, asmild dal, st 20, 8800, dk
1	10, cl gujarrak, 21668, es	10, cl gujarral, 21668, es
1:	26, cl palmitos, 4130, es	26, cl palmitos, 4130, es
1:	campbellparade, bondi beach, au	campbell parade, bondi beach, au
1:	1a, avenue du moulin vieux, venerque, 31810, fr	1a, avenue du moulin vieux, venerque, 31810, fr
1:	60, cjuan carlos i, 5120, es	60, cl juan carlos i, 5120, es
1	7a, ag aplmeritas, 21430, es	7a, ag palmeritas, 21430, es

6- معرفة اعداد الحشود من صور ملتقطه :

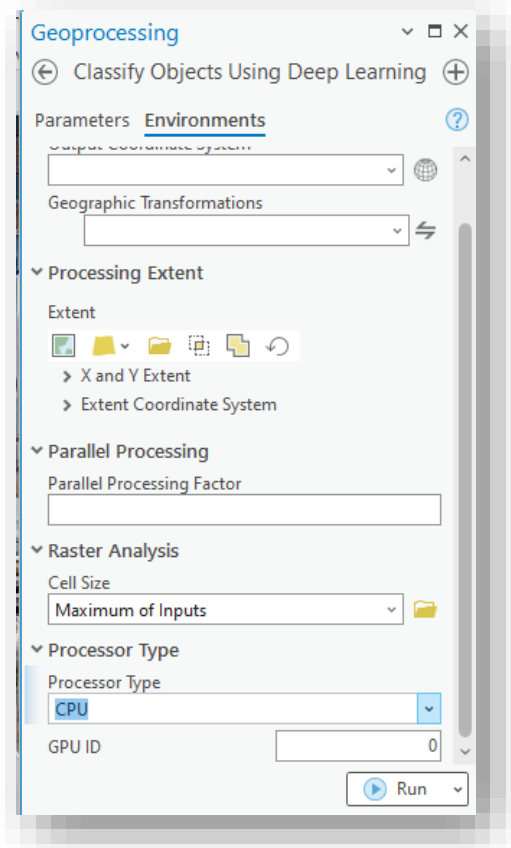
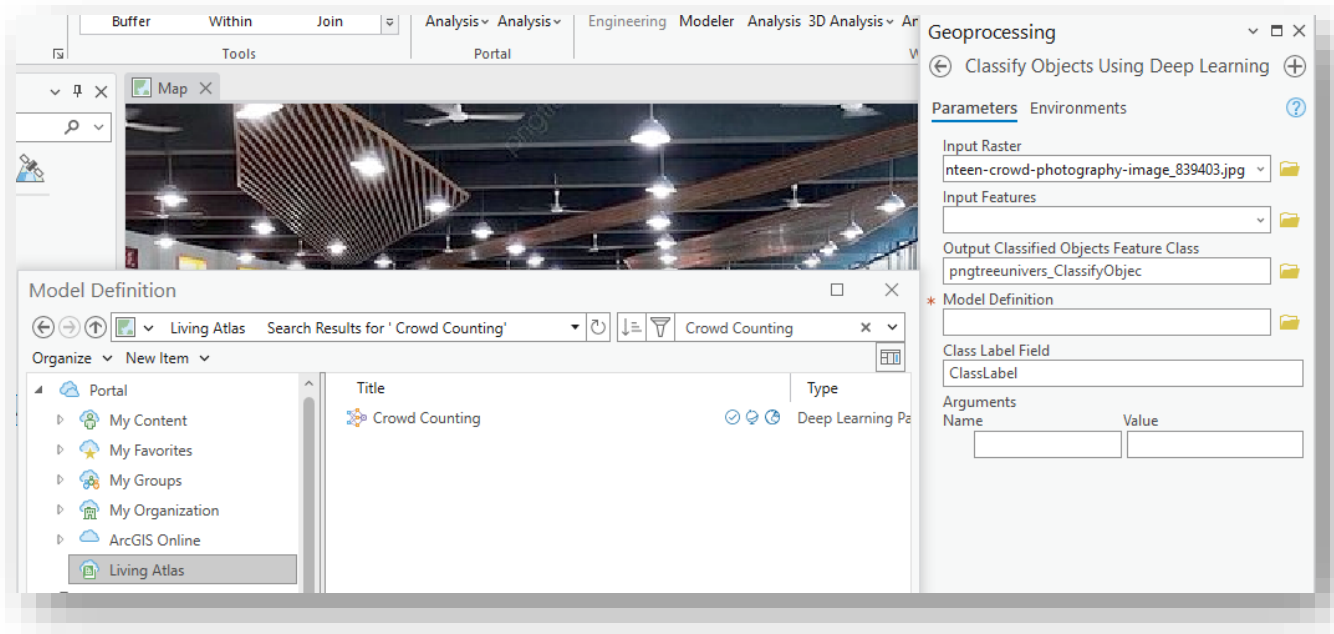
تحميل النموذج

<https://www.arcgis.com/home/item.html?id=4e427c0924b0480991c6ebc58b5e7be6>



-يتم استخدام نموذج Crowd Counting pretrained من موقع Living Atlas.

-من أداة Classify Object Using Deep Learning.




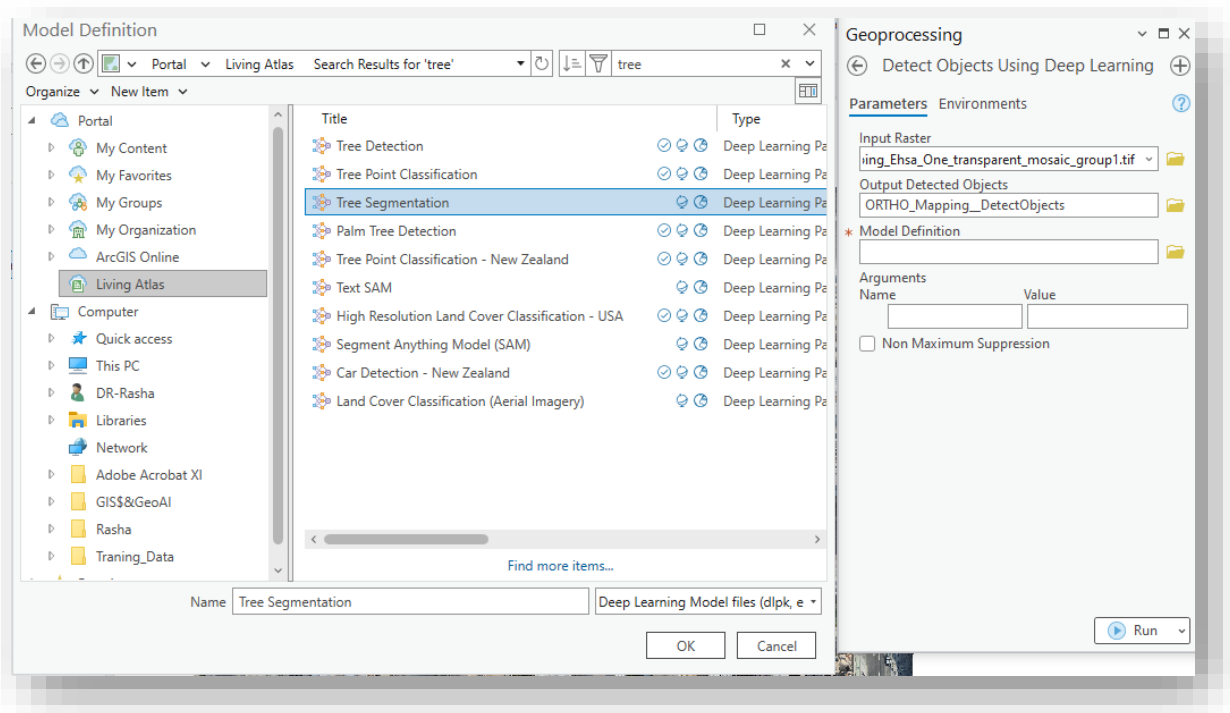
-ثم Run بعد الانتهاء يظهر لنا اعداد الحشود داخل طبقة جديدة كما موضح.



7- توكيع الاشجار من صور الطائرات بدون الطيار:

استخدام أداة Detect Object Using Deep Learning

يتم اختيار نموذج Tree Segmentation من Living Atlas



8- استخراج خطوط الكهرباء من بيانات الليدار:

يتم تحميل البيانات من الرابط التالي ويمكن استخدام اى بيانات LAS اخرى للتدريب .

<https://learn.arcgis.com/en/projects/classify-powerlines-from-lidar-point-clouds/#download-and-explore-data>

الملفات عبارة عن 3 مجلدات

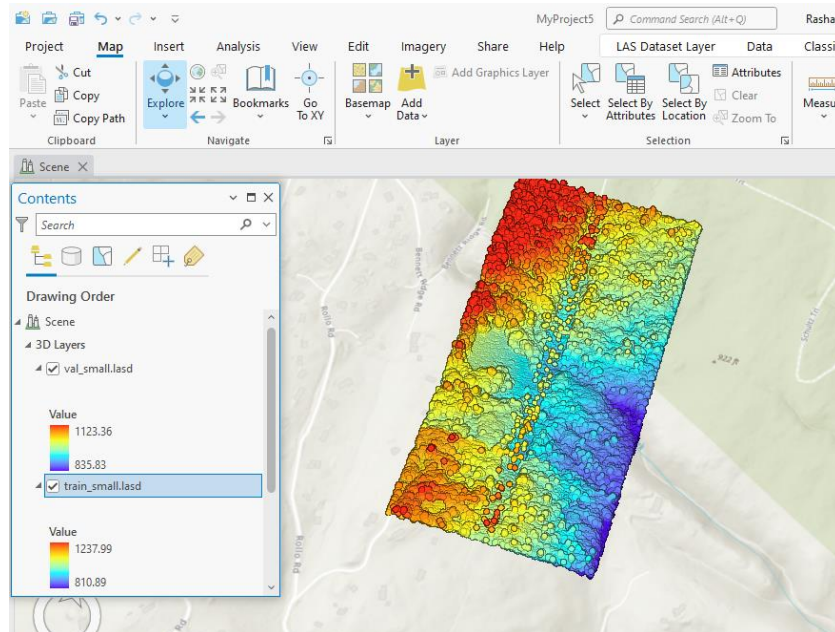
مجلد small Data ويحتوى على :

- بيانات التدريب (train-small.las) والتي تستخدم لتدريب النموذج.
- بيانات التحقق (val-small.las) للتحقق من صحة النموذج .
- حدود للبيانات التدريبية وبيانات التحقق .
- طبقة نموذج ارتفاعات رقمية لمنطقة الدراسة .

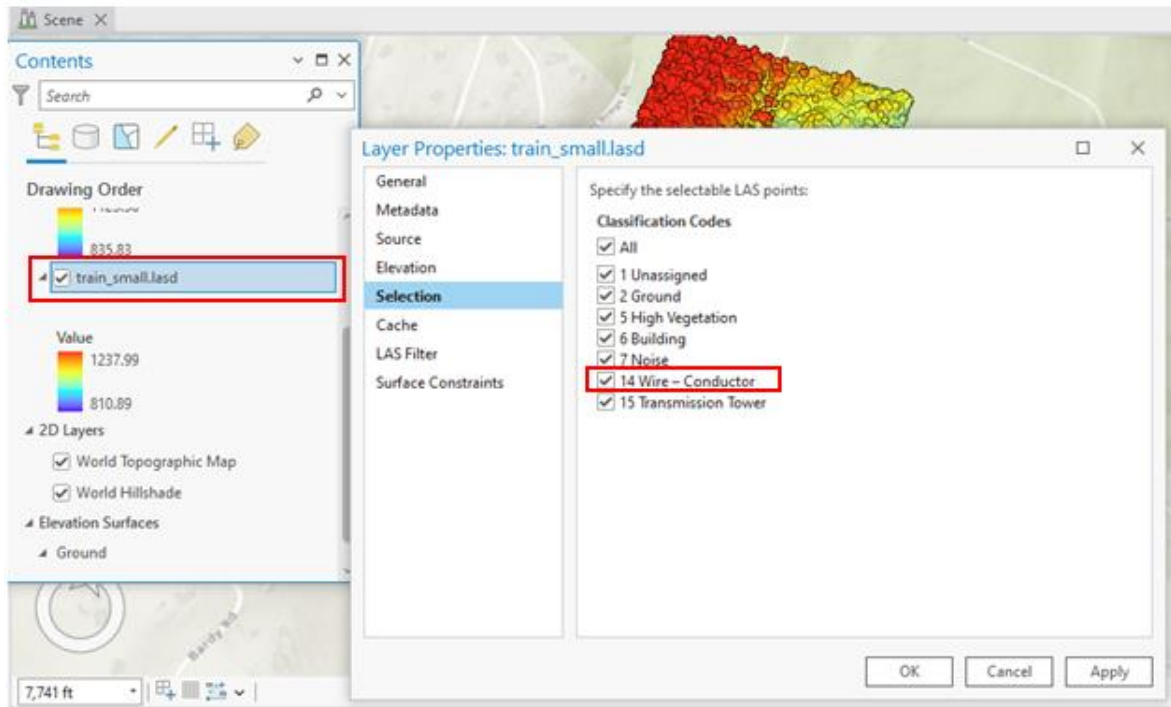
مجلد testdata.zip يحتوي على مجموعة بيانات اختبارية وحدود المعالجة وDEM

مجلد results.zip يحتوي على نتائج التدريب من مجموعة البيانات الكبيرة التي يمكنك استخدامها بدلاً من تدريب النموذج لمجموعة البيانات الكبيرة.

يتم ادخال بيانات ليدار LAS والتي تم تنزيلها .




كليك يمين على الطبقة واختيار Properties نجد جميع الطبقات التي تجمعها صورة الليدار : من ضمنها – Wire Conductor وهي المعنية بالاهتمام في هذا التطبيق.

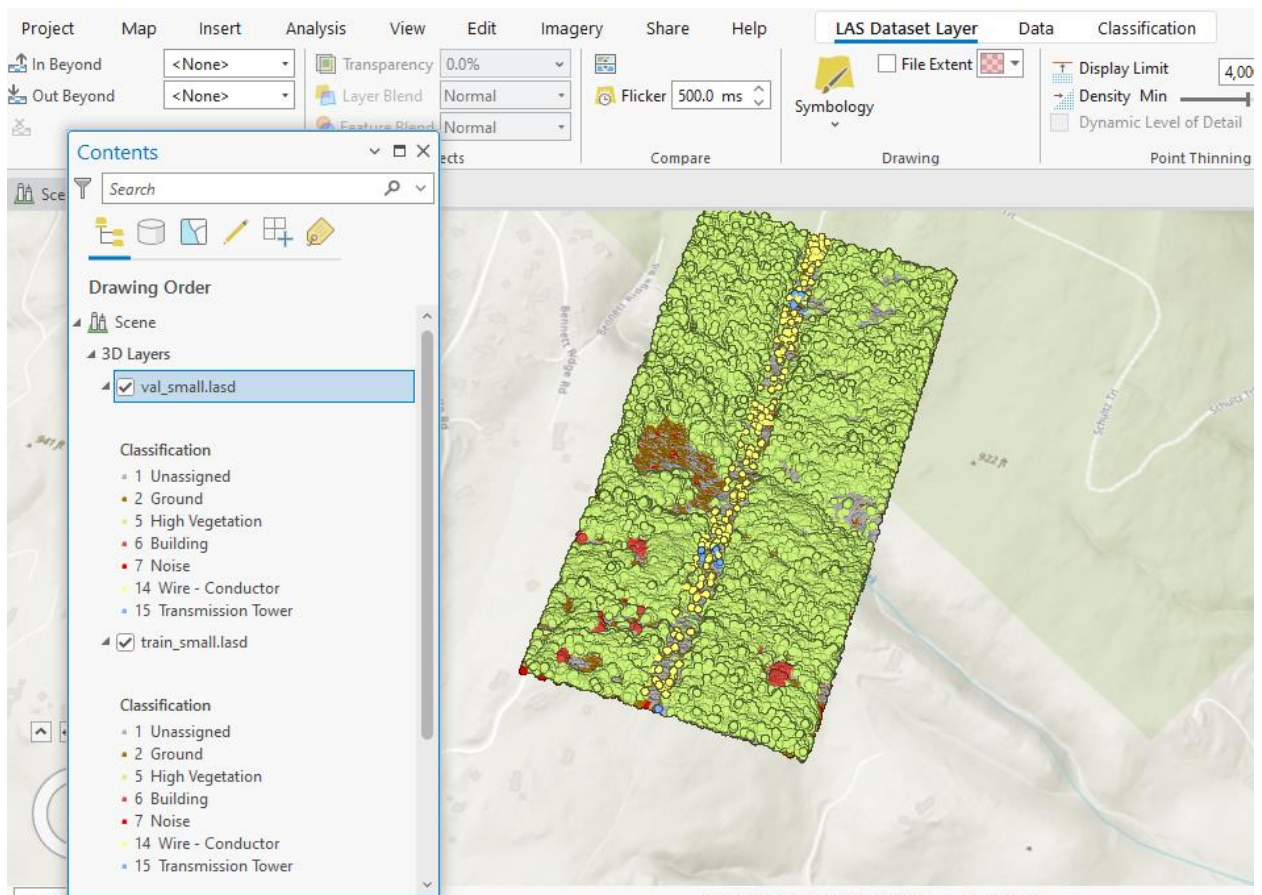
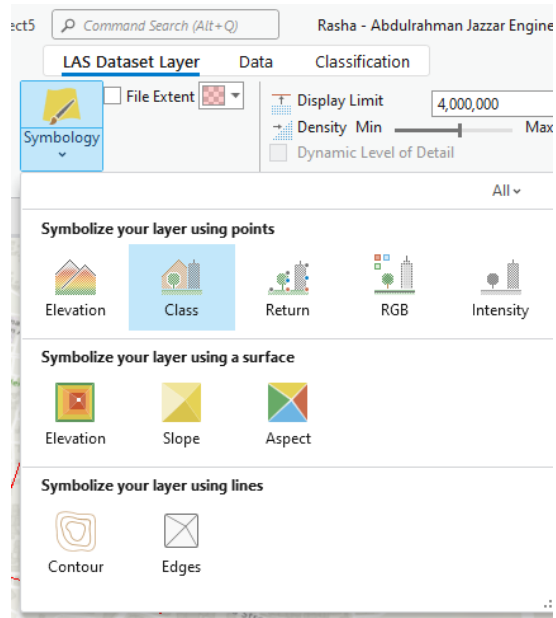


فالهدف هو تدريب نموذج لاكتشاف نقاط الليدار التي تمثل خطوط الكهرباء حتى تتمكن من تقييم مخاطر حرائق الغابات لخطوط الكهرباء القريبة من الأشجار بشكل أفضل.

من اختار LAS Dataset Layer Symbology



تسندل قائمة اختار منها Class



بعد ذلك تأتي خطوة إعداد مجموعة بيانات التدريب ؛ من أداة Prepare Point Cloud Training Data ؛ يتم ادخال بيانات التدريب وبيانات التحقق وحدود كل منهما واختيار المرجع طبقة Dem ؛ ويراعى كتابة الطبقات المطلوب استثنائها داخل Excluded Class Codes من البيانات التدريبية والتي لسنا بحاجة اليها ؛ وفي هذا المثال تم كتابة 2 وهي تمثل Groungd و 7 وهي noise وفي Block Size يراعى كتابة قيمة مناسبة لقطر كل كتلة من بيانات التدريب التي سيتم إنشاؤها وتم كتابة 82

Geoprocessing

Prepare Point Cloud Training Data

Parameters Environments

Input Point Cloud
train_small.lasd

Training Boundary Features
bnd_train_small

Validation Point Cloud
val_small.lasd

Validation Boundary Features
bnd_val_small

Reference Surface
dem_small.tif

Excluded Class Codes
2
7
Add another

Filter Blocks By Class Code
Add another


Output Training Data
C:\Users\DR-Rasha\Documents\ArcGIS\Projects\

Block Size
82 US Survey Yards

Block Point Limit
8192

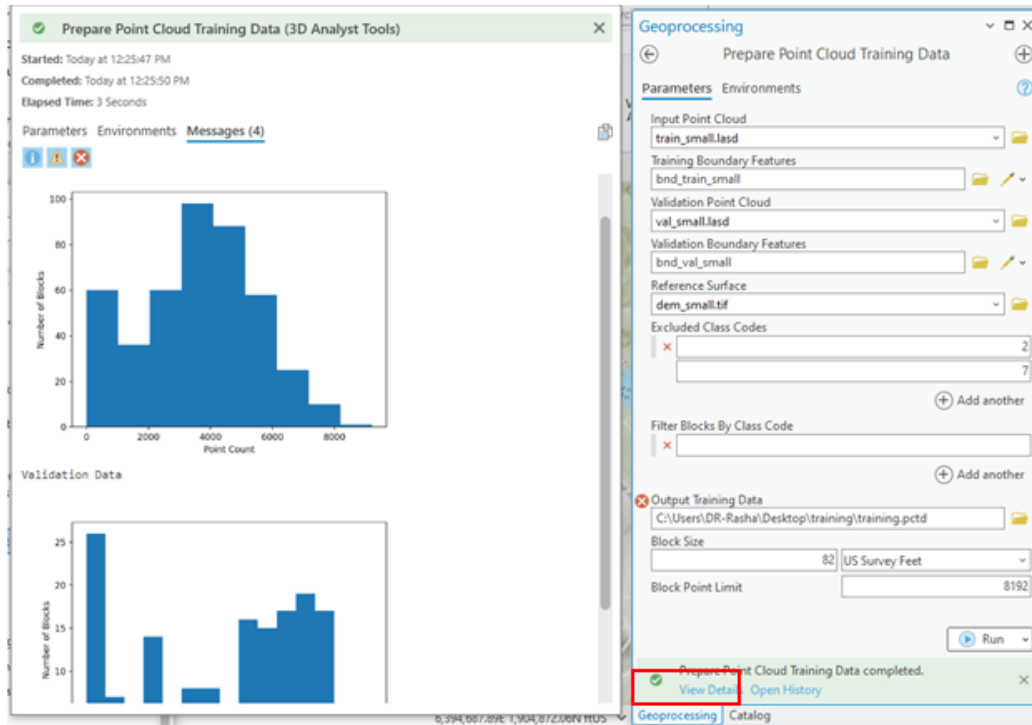
Run

تحديد مكان حفظ المخرجات (مجلد Reselt) واسمه



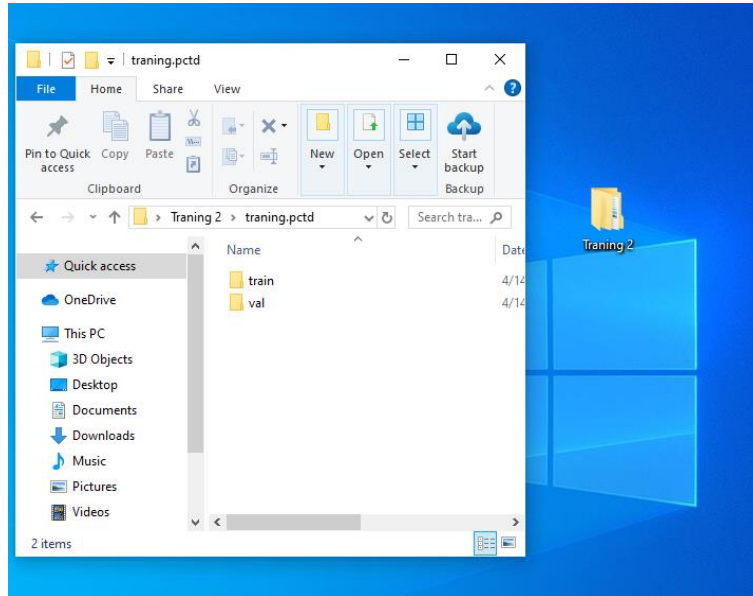
ثم Run .

ولمشاهدة النتيجة

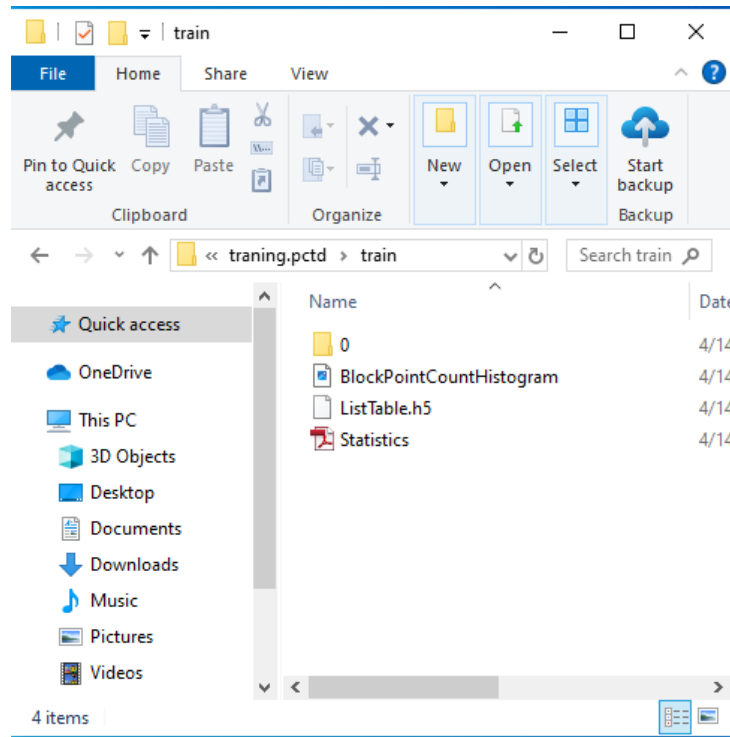


تُظهر الرسوم البيانية جميع الكتل وهي تقريبًا تحتوي على عدد نقاط أقل من 8000، مما يؤكد أن حجم الكتلة البالغ 82 قدمًا والحد الافتراضي لنقطة الكتلة البالغ 8192 مناسبًا لمجموعات البيانات هذه.

نذهب الى مكان حفظ الملف المخرج (ناتج الأداة) نجد ان المخرجات عبارة عن ملفين على النحو الموضح أدناه ؛



كلا منهما يحتوى على



بعد ذلك يتم تدريب نموذج التصنيف باستخدام أداة Train Point Cloud Classification Model

Geoprocessing Train Point Cloud Classification Model

Parameters Environments

Input Training Data
C:\LearnArcGIS\DL\results\training_data_small.pctd

Pre-trained Model

Model Architecture
RandLA-Net

Attribute Selection Select All

Intensity
 Return Number
 Number of Returns
 Red Band
 Green Band
 Blue Band
 Relative Height

Output Model Location
results

Output Model Name
Powerline_classification_model_small_data

Minimum Points Per Block 1000

Manage Classes

Class Remapping

Current Class	Remapped Class
14	14
OTHER	1

Class Description

Current Code	Class Description
14	Wire Conductor
1	Unclassified

▼ Training Parameters

Model Selection Criteria
 Recall ▼

Maximum Number of Epochs

Iterations Per Epoch (%)

Learning Rate Strategy
 One Cycle Learning Rate ▼


Learning Rate

Batch Size

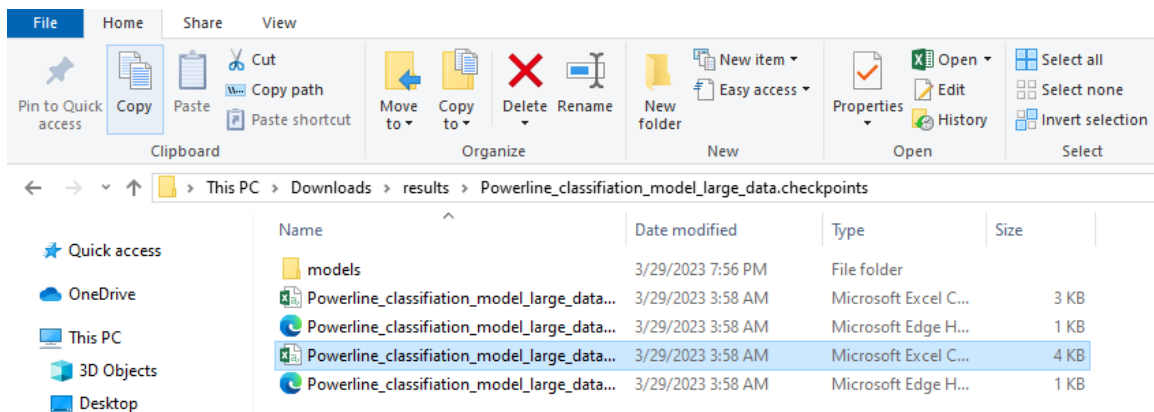
Stop training when model no longer improves

▼

نتائج الأداة :



Powerline_classification_model_افتح :

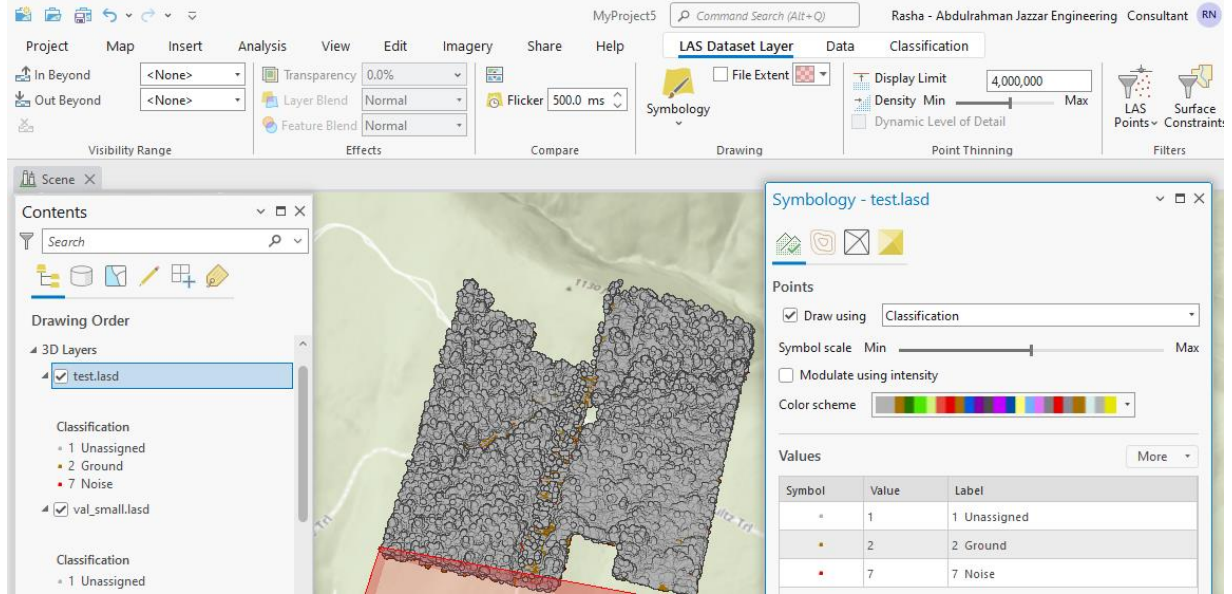


	A	B	C	D	E	F	G	H	I	J
8	4	1	Unassigned	0.999439	0.999098679	0.999269				
9	2	1	Unassigned	0.999238	0.998703438	0.99897				
10	6	1	Unassigned	0.999313	0.998672663	0.998992				
11	1	1	Unassigned	0.998149	0.998441761	0.998294				
12	3	1	Unassigned	0.999256	0.998313948	0.998784				
13	18	14	Wire Conductor	0.987223	0.993655113	0.990359				
14	19	14	Wire Conductor	0.993075	0.992359409	0.992704				
15	13	14	Wire Conductor	0.99352	0.991258864	0.992378				
16	20	14	Wire Conductor	0.993872	0.99091856	0.992387				
17	12	14	Wire Conductor	0.992222	0.990756629	0.991474				
18	8	14	Wire Conductor	0.979276	0.990622237	0.984668				
19	16	14	Wire Conductor	0.985546	0.990126257	0.987639				
20	15	14	Wire Conductor	0.985575	0.989504208	0.987403				
21	9	14	Wire Conductor	0.987624	0.988801357	0.988044				
22	17	14	Wire Conductor	0.994274	0.988253146	0.991224				
23	7	14	Wire Conductor	0.975834	0.987554467	0.981346				
24	14	14	Wire Conductor	0.995049	0.986638286	0.990812				
25	11	14	Wire Conductor	0.990062	0.986187803	0.987985				
26	4	14	Wire Conductor	0.974817	0.984888328	0.979434				
27	6	14	Wire Conductor	0.963859	0.98158612	0.972022				
28	5	14	Wire Conductor	0.986613	0.981014286	0.98359				
29	3	14	Wire Conductor	0.954035	0.979420959	0.966053				
30	10	14	Wire Conductor	0.981067	0.979385083	0.979893				

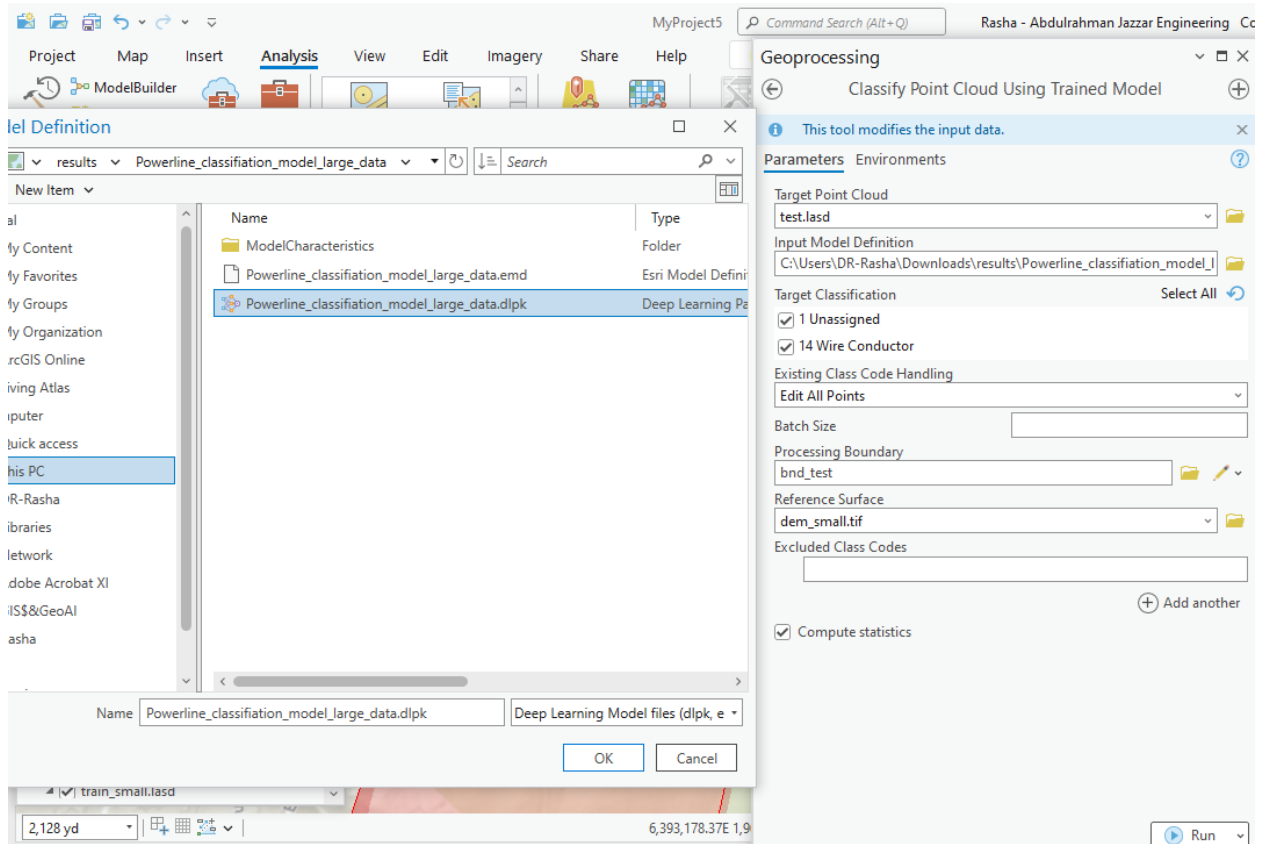
تصنيف خطوط الكهرباء باستخدام النموذج المدرب:

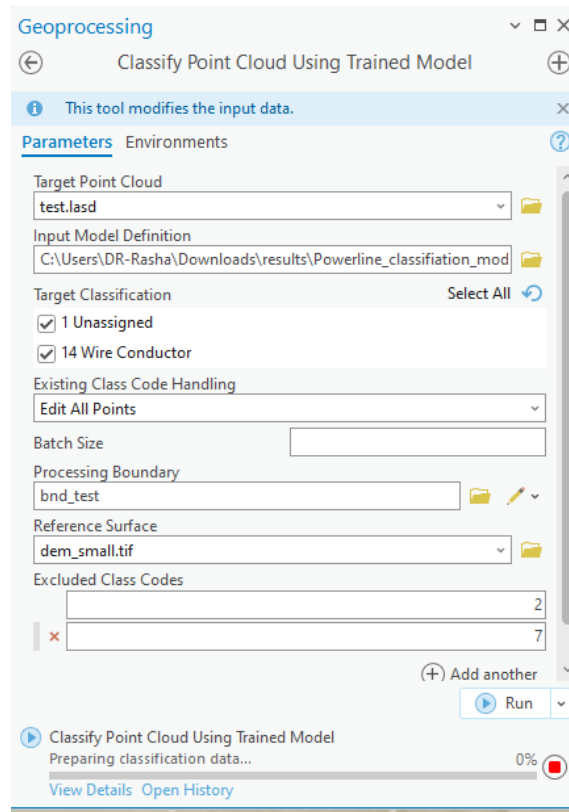
لدينا بيانات يوجد بها تصنيف Ground و noise وباقي التصنيفات عبارة عن unassigned موجودة في مجلد test

يتم اضافتها ثم اختيار class من Sympology وذلك على النحو التالي:

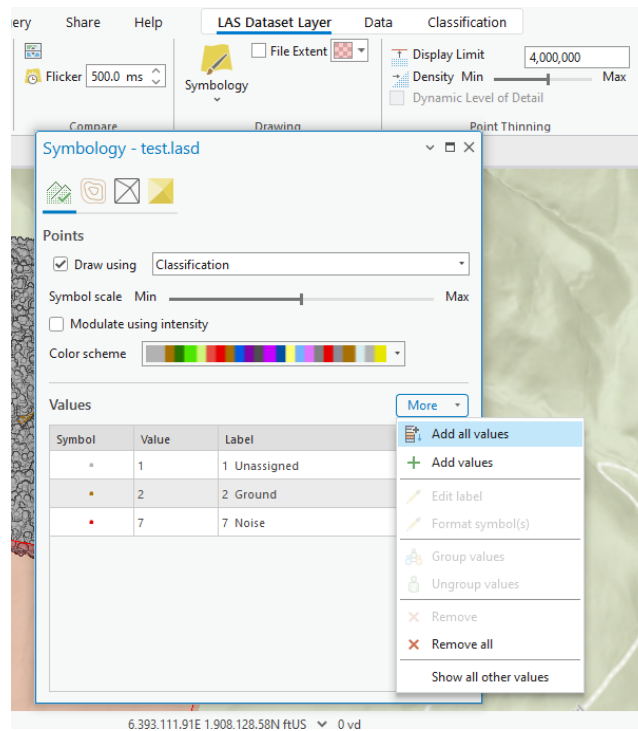


Classify Point Cloud Using Trained Model من أداة





وبعد الانتهاء من عمل الأداة




Symbology - test.lasd


Points

Draw using Classification

test.lasd

Select values to add Options

Symbol	Value	Label
	14	14 Wire - Conductor



قائمة المراجع والمصادر

مراجع باللغة العربية:

- بانوس لوريداس؛ الخوارزميات؛ ترجمة إبراهيم سند احمد؛ مراجعة شيماء طه الريدى؛ مؤسسة هنداوى للنشر؛ 2017.
- ميلادوزان؛ تعلم الآلة وعلم البيانات؛ الأساليب والمفاهيم والخوارزميات والأدوات؛ ترجمة علاء طعيمة.

مراجع باللغة الانجليزية:

- Andrew T.Nb , Michael I.jordan , Yair Weiss , One Spectral Clustering Analysis and an algorithm
- Krishna Rungta ,TensorFlow in 1 Day: Make your own Neural Network,2018.
- Jie Wang, An Intuitive Tutorial to Gaussian Process Regression, University of Waterloo, Waterloo, ON, N2L 3G1, Canada,2024.
- C. E. Rasmussen & C. K. I. Williams, Gaussian Processes for Machine Learning, the MIT Press, 2006

مواقع من شبكة الانترنت:

- <https://pro.arcgis.com/en/pro-app/latest/tool-reference/geoai/how-autodl-works.htm>
- <https://alioh.github.io/DSND-Notes-2/>
- https://medium.com/@brijesh_soni/understanding-boosting-in-machine-learning-a-comprehensive-guide-bdeaa1167a6
- <https://sciences24.com/%D9%81%D9%87%D9%85%D8%AE%D9%88%D8%A7%D8%B1%D8%B2%D9%85%D9%8A%D8%A9-%D8%A7%D9%86%D8%AD%D8%AF%D8%A7%D8%B1%D8%A7%D9%84%D9%85%D8%AA%D8%AC%D8%A9-%D8%A7%D9%84%D8%AF%D8%A7%D8%B9%D9%85-sv%D9%8Cr-%D9%85/>
- <https://github.com/RiadKatby/machine-learning-models/blob/main/machine-learning-for-everyone.md>
- <https://doc.arcgis.com/en/pretrained-models/latest/imagery/introduction-to-agricultural-field-delineation.htm>
- <https://learn.arcgis.com/en/projects/classify-powerlines-from-lidar-point-clouds/#download-and-explore-data>
- <https://pro.arcgis.com/en/pro-app/latest/help/analysis/raster-functions/band-arithmetic-function.htm>
- <https://pro.arcgis.com/en/pro-app/latest/tool-reference/image-analyst/how-zonal-statistics-works.htm>