



استخدام الذكاء الاصطناعي للتنبؤ بالطقس

١/ ياسر عبدالجواد السيد

مدير مركز تنبؤات مطار القاهرة

شهدت السنوات الأخيرة تطورًا ملحوظًا في استخدام الذكاء الاصطناعي، وخصوصًا تقنيات التعلم العميق المعتمدة على الشبكات العصبية، في تطبيقات متنوعة. ويُعتبر مجال التنبؤ بالطقس من أبرز المجالات التي يمكن أن تستفيد من هذه التقنيات، لما توفره من إمكانيات لتحسين دقة وجودة التنبؤات، وتعزيز الفهم المنهجي للظواهر الجوية.

تستعرض المقالة دور الذكاء الاصطناعي في مراحل التنبؤ المختلفة، بدءًا من العمليات الحسابية المعقدة، مرورًا بالتطبيقات العملية، وصولًا إلى طرق إيصال المعلومات للمستخدمين بشكل فعال. كما تركز على التحديات والقضايا التي قد تنشأ نتيجة دمج هذه التقنيات الحديثة في أنظمة التنبؤ التقليدية، بما يشمل التعامل مع البيانات الكبيرة، والتحقق من دقة النماذج، وضمان موثوقية النتائج في ظروف متغيرة.



ما هو الذكاء الاصطناعي؟

يُعد تعريف الذكاء الاصطناعي بدقة من أبرز التحديات التي تواجه الباحثين. بشكل عام، يُمكن النظر إليه على أنه مجموعة واسعة من التقنيات المبنية على أسس رياضية وعلوم الحاسوب، تهدف إلى محاكاة بعض جوانب الذكاء البشري، مثل الاستدلال والإبداع.


ورغم أن الذكاء الاصطناعي أصبح شائعًا حديثًا، فإن جذوره تعود إلى خمسينيات القرن الماضي، حين كان يتمثل في أنظمة خبيرة تعتمد على قواعد وتعليمات محددة من قبل الإنسان وتنفذها الآلة. أما الأساليب الحديثة، فتختلف جذريًا، إذ لم يعد الإنسان يحدد القواعد بشكل مباشر، بل تُطوّر برامج حاسوبية قادرة على تعلّم الأنماط والعلاقات من البيانات، وهو ما يُعرف بـ التعلّم الآلي، والذي يعتمد أساسًا على الشبكات العصبية العميقة.



وتحاكي الشبكات العصبية العميقة طريقة عمل الخلايا العصبية البيولوجية، إذ تتكون من مجموعة من "الخلايا العصبية الاصطناعية" المنظمة في طبقات متعددة (انظر الشكل ١)، تقوم بتحويل إشارة الإدخال (مثل درجة الحرارة في الزمن t) إلى إشارة إخراج (مثل درجة الحرارة في الزمن $t+١$ ساعة).

أولاً: في مرحلة التعلّم (أو التدريب)، تتعلّم الشبكة من البيانات بشكل تكراري من أجل حل مشكلة معينة، كمثال: توقع درجة الحرارة بعد ساعة. عمليًا، تتضمن هذه العملية معايرة الأوزان (الاتصالات) بين طبقات الشبكة للحصول على أفضل استجابة ممكنة. ويتطلب ذلك توفر مجموعة بيانات كبيرة تشمل مجموعة متنوعة من السيناريوهات المحتملة، إلى جانب موارد حوسبة ضخمة. وقد تكون هذه المرحلة طويلة ومكلفة، خاصةً مع تعقيد الشبكة أو المشكلة المدروسة.

ثانيًا: مرحلة الاستدلال، والتي تأتي بعد اكتمال التدريب، فتُستخدم فيها الشبكة العصبية كنموذج تنبؤي على بيانات جديدة، وتتميز هذه المرحلة بسرعتها وكفاءتها مقارنة بمرحلة التدريب.



ورغم اقتراح الشبكات العصبية الاصطناعية منذ أربعينيات القرن العشرين، إلا أن استخدامها ظل محدودًا حتى بداية الألفية الثالثة، حين أدّى التقدم في قدرات الحوسبة، خصوصًا مع ظهور وحدات معالجة الرسومات (GPUs)، إلى إحياء هذه التقنيات، مدعومًا بتوافر مجموعات ضخمة من البيانات.

وفي بقية هذه المقالة، سيتم استخدام مصطلح "الذكاء الاصطناعي" للإشارة بشكل رئيسي إلى الأساليب القائمة على الشبكات العصبية العميقة. ومن بين أبرز هذه الأساليب، الشبكات العصبية الالتفافية (Convolutional Neural Networks - CNNs)، التي طوّرها LeCun وآخرون [١]، والمصممة خصيصًا لمعالجة الصور، والتي تُعد من التقنيات الرئيسية المستخدمة حاليًا في تطبيقات التنبؤ بالطقس.

استخدام الذكاء الاصطناعي للتنبؤ بالطقس



يُعد التنبؤ بالطقس نتيجة سلسلة معقدة من العمليات، ويشكل نموذج التنبؤ العددي العنصر المركزي فيها وتوسع الجهات المعنية بالأرصاد الجوية باستمرار إلى تحسين هذه النماذج، سواء عبر زيادة دقة الشبكات الحاسوبية أو تعقيد التمثيل الفيزيائي للعمليات الجوية ومع ذلك، فإن هذه التحسينات تتطلب استثمارات كبيرة، سواء تطوير النماذج أو توفير الموارد الحاسوبية اللازمة لتشغيلها في المقابل، تتميز خوارزميات الذكاء الاصطناعي بسرعتها العالية، خاصة في مرحلة الاستدلال، ما يمكنها من حل المشكلات الفيزيائية المعقدة بكفاءة أعلى. فبينما تعتمد الأساليب التقليدية على حل مئات أو آلاف المعادلات التفاضلية، يمكن للذكاء الوصول إلى نتائج مماثلة بتكلفة حسابية أقل، مما يجعله أداة واعدة لتسريع عمليات التنبؤ بالطقس وتطبيقات أخرى.

جدير بالذكر أن استخدام الذكاء الاصطناعي في علم الأرصاد الجوية ليس بالأمر الجديد. فمنذ تسعينيات القرن العشرين، استُخدمت تقنيات الذكاء الاصطناعي في تطوير أساليب المعالجة الإحصائية اللاحقة (Post-processing) لتوقعات الطقس، والتي مكّنت من تحسين التنبؤات عبر تقليل الأخطاء المنهجية فيها [٢].

ومع ذلك، لم يبدأ الذكاء الاصطناعي في التوسع داخل جوهر النمذجة الجوية إلا مؤخرًا، بفضل التقدم في تقنيات التعلم العميق وزيادة توفر البيانات والقدرات الحاسوبية.


ما الاختلافات بين النماذج الفيزيائية (العددية) ونماذج الذكاء الاصطناعي؟

تعمل نماذج الذكاء الاصطناعي بطريقة مختلفة تمامًا عن النماذج الفيزيائية، إذ تعتمد على التعلّم الذاتي من كميات ضخمة من البيانات لاستخلاص أفضل العلاقات الإحصائية التي تُمكنها من التحول من بيانات الإدخال إلى مخرجات دقيقة. وعلى عكس النماذج الفيزيائية التي تستند إلى معادلات محددة وضعها الإنسان، تُعد نماذج الذكاء الاصطناعي أقل قابلية للتفسير - وغالبًا ما يُشار إليها بمصطلح "الصندوق الأسود" - كما أنها لا تضمن التزامًا مباشرًا بالقوانين الفيزيائية.

ومع ذلك، تمتلك هذه النماذج القدرة على اكتشاف علاقات معقدة وغير خطية قد لا يكون العلماء فهموها أو حدّدوا طبيعتها بعد، ما يفتح آفاقًا جديدة لفهم الظواهر الجوية.

على سبيل المثال، عند التنبؤ بدرجة الحرارة في وقت معين، يعتمد النموذج الفيزيائي على حل معادلات تفاضلية تصف السلوك الجوي استنادًا إلى القوانين الفيزيائية المعروفة. في المقابل، يعتمد نموذج الذكاء الاصطناعي على سلسلة من العلاقات الإحصائية التي تتعلمها الشبكة العصبية خلال مرحلة التدريب، استنادًا إلى كميات هائلة من البيانات التاريخية.

وبالتالي، فإن النمذجة الفيزيائية ونمذجة الذكاء الاصطناعي تمثلان نهجين مختلفين جذريًا في طبيعة عملهما، ولكنهما في الوقت ذاته متكاملان في معالجة المشكلات التنبؤية المعقدة (٢).



نحو تهجين النهج الفيزيائي والذكاء الاصطناعي للنمذجة الجوية

يمكن دمج الذكاء الاصطناعي في عملية التنبؤ الجوي بطرق متعددة كما هو موضح في الشكل رقم (٢). وقد أدت الطبيعة التكميلية بين النماذج الفيزيائية وتقنيات الذكاء الاصطناعي إلى تطوير أنظمة تنبؤ هجينة، تجمع بين دقة النمذجة الفيزيائية ومرونة وقدرات التعلم في مجال الذكاء الاصطناعي.

ويتمثل أحد أساليب الدمج الشائعة في استبدال المكونات الأكثر تكلفة حسابيًا أو الأقل تمثيلًا في النموذج الفيزيائي بخوارزميات الذكاء الاصطناعي. على سبيل المثال، يمكن استخدام نموذج تعلم عميق ليحل محل مكون فيزيائي معقد، مما يساهم في تقليل زمن الحساب مع الحفاظ على جودة التنبؤ.


وأظهرت دراسات أخرى إمكانية استخدام الذكاء الاصطناعي لتحسين خصائص محددة للتنبؤات، مثل الدقة المكانية أو الزمنية، مما يساهم في رفع جودة التوقعات بشكل عام، مع تقليل التكلفة الحاسوبية.

وتُعد المعلومات الفيزيائية، التي تهدف إلى محاكاة تأثيرات العمليات الدقيقة مثل: الإشعاع، الحمل الحراري، والاضطرابات الجوية، من بين أغلى مكونات النماذج الفيزيائية وأكثرها مساهمة في عدم اليقين في التنبؤات الجوية والمناخية. لذلك، بدأت العديد من الدراسات الحديثة في استكشاف إمكانية استبدال هذه المعلومات جزئيًا أو كليًا بخوارزميات الذكاء الاصطناعي، وقد أظهرت النتائج الأولية لهذه الأبحاث مؤشرات واعدة للغاية [٣].


ويوضح المثال في الشكل رقم (٣) اتساقًا عاليًا بين تنبؤات هطول الأمطار الناتجة عن نموذج فيزيائي تقليدي ونموذج هجين، حيث تقوم شبكة عصبية بتعلم العمليات المرتبطة بالحمل الحراري العميق، مما يدل على فعالية هذا النهج الهجين.

تعتبر زيادة الدقة المكانية في نماذج التنبؤ العددي وسيلة فعالة لتحسين تمثيل الظواهر الجوية صغيرة النطاق. وتكتسب هذه الدقة أهمية خاصة عند دراسة الأحداث ذات التأثير الكبير، مثل العواصف الرعدية، الضباب، والموجات الحرارية. إلا أن هذا التحسين في الدقة يرافقه ارتفاع كبير في متطلبات الحوسبة، مما يجعل تطبيقه على نطاق واسع أمرًا مكلفًا وصعب التنفيذ في بعض الحالات.

Hybrid AI-Physical Model



Traditional Physical Model




كبديل لذلك، يُمكن اللجوء إلى ما يُعرف بـ التخفيض الإحصائي (Statistical Downscaling)، وهو أسلوب يقوم على تعلّم العلاقة الإحصائية بين مخرجات النماذج منخفضة الدقة وتلك عالية الدقة. من خلال هذه الطريقة، يصبح من الممكن محاكاة التنبؤات على المستوى المحلي دون الحاجة إلى تشغيل نموذج فيزيائي عالي الدقة، عبر تطبيق العلاقة المتعلّمة مباشرة على مخرجات النموذج منخفض الدقة. وقد أظهرت العديد من الدراسات فعالية استخدام الشبكات العصبية في هذا السياق، نظرًا لقدرتها على استخراج العلاقات المعقدة وتحقيق تحسينات دقيقة في التوقعات.

أنظمة التنبؤ بالمجموعات في الأرصاد الجوية (Ensemble Forecasting Systems)

تعتمد هذه الأنظمة على تشغيل عدة نماذج تنبؤية (أو نسخ مختلفة من النموذج الواحد) مع تغيير طفيف في الشروط الأولية أو المعلمات الفيزيائية، مما يُنتج مجموعة من السيناريوهات المحتملة للطقس. هذا الأسلوب يُقلل من عدم اليقين في التنبؤات ويُعطي نطاقًا من النتائج المُحتملة بدلاً من نتيجة واحدة.

مكونات النظام



التنوع في المعادلات الفيزيائية
تعديل معادلات التبادل الحراري أو تشبع السحب في النموذج.



التنوع في النماذج
تشغيل نماذج أرصاد مختلفة (مثل، ECMWF، GFS، WRF) معًا.



التنوع في الشروط الأولية
استخدام عدة بدايات مختلفة للتنبؤ (مثل تغيير درجات الحرارة أو الرطوبة الأولية بنسبة $\pm 0.5\%$).

فوائدها في مجال الطيران

تحديد عدم اليقين:

تُظهر النتائج نطاقًا من الاحتمالات (مثل: ٧٠% فرصة لتشكيل ضباب في مطار دبي بين ٣ - ٥ صباحًا).

تحسين قرارات الطيران:

تساعد شركات الطيران على اختيار المسارات المثلى وتجنب الظروف الخطرة (مثل: الاضطرابات الجوية أو العواصف).

التنبؤ بالأحداث النادرة:

مثل العواصف الرعدية المفاجئة أو الرياح القصية (Wind Shear).


مثال تطبيقي:

إذا أشار ٦٠ % من نماذج المجموعة إلى تشكل ضباب كثيف في مطار القاهرة، بينما أشار ٤٠ % إلى ضباب خفيف، يُعتبر الضباب الكثيف احتمالاً رئيسياً، وتُتخذ إجراءات وقائية (مثل تأخير الرحلات).

التحديات:

أنظمة مشهورة:

- ١- ECMWF Ensemble (أوروبا)
- ٢- GEFS (الولايات المتحدة)
- ٣- CMA-EPS (الصين)



- ١- التكلفة الحسابية العالية: تشغيل عشرات النماذج يتطلب موارد حاسوبية ضخمة.
- ٢- صعوبة التفسير: يحتاج الطيارون ومراقبو الحركة الجوية إلى تدريب لفهم خرائط الاحتمالات.
- ٣- الحاجة إلى معايرة دقيقة: عدم توازن النماذج قد يؤدي إلى تنبؤات مضللة.

التكامل مع الذكاء الاصطناعي

تُستخدم تقنيات التعلم الآلي (ML) لتحسين أنظمة المجموعات عن طريق:

- تحليل نتائج النماذج وتحديد السيناريو الأكثر احتمالاً.
- دمج بيانات الرادار والأقمار الصناعية في الوقت الحقيقي.
- التنبؤ بسلوك الطقس في المناطق ذات البيانات المحدودة (مثل المحيطات).

الفرق بين التنبؤ التقليدي والمجموعات:




التنبؤ بالمجموعات (Ensemble):

يعتمد على ٢٠-٥٠ نموذجًا يُعطي نطاقًا من الاحتمالات، أعلى تكلفة حسابية.

التنبؤ التقليدي (Deterministic):

يعتمد على نموذج واحد، يُعطي نتيجة واحدة، أقل تكلفة.

يوضح شكل رقم (٤) مثالاً عملياً على تطبيق الذكاء الاصطناعي في تخفيض نسبة الخطأ في دقة التنبؤ بدرجة الحرارة، حيث تُظهر النتائج توافقاً جيداً مع التوقعات عالية الدقة [٤].



يتعلق المثال الأخير بـ أنظمة التنبؤ بالمجموعات، والتي تُستخدم لتوصيف مجموعة من السيناريوهات المحتملة للطقس، وذلك من خلال الإنتاج المتوازي لعدة توقعات مستقلة. وقد أصبحت هذه الأنظمة اليوم في قلب استراتيجيات التنبؤ للعديد من مراكز الأرصاد الجوية حول العالم، نظرًا لقدرتها على تقدير عدم اليقين وتقديم معلومات احتمالية أكثر اكتمالاً من التوقعات الفردية.

ومع ذلك، يواجه التنبؤ بالمجموعات تحديًا رئيسيًا يتمثل في العدد المحدود من الأعضاء (أو السيناريوهات) المستخدمة عمليًا، والذي نادرًا ما يتجاوز ٥٠ عضوًا، وذلك بسبب القيود المفروضة على موارد الحوسبة. ومع ذلك، فإن الحصول على توصيف دقيق للتوزيع الاحتمالي للحالة المستقبلية للغلاف الجوي يتطلب إنتاج عدة مئات أو حتى آلاف الأعضاء، وهو أمر مكلف جدًا من ناحية الحوسبة عند الاعتماد فقط على النماذج الفيزيائية.

هل يمكن الاستفادة من الذكاء الاصطناعي لتوليد أعضاء إضافيين بطريقة فعّالة؟

تشير الدراسات الحديثة [٥]. إلى إجابات مشجعة للغاية. فمن خلال الاعتماد على خوارزميات الذكاء الاصطناعي التوليدي (Generative AI) - وهي فئة من تقنيات الذكاء الاصطناعي المصممة لإنشاء محتوى جديد، كما هو الحال في تطبيقات مثل ChatGPT أو DALL·E - أصبح من الممكن إنتاج حقول طقس واقعية تسترشد بالمحاكاة الفيزيائية.

وتُظهر هذه المقاربات أنه يمكن إنشاء توقعات مجموعات هجينة تتألف من عشرات أو حتى مئات الأعضاء، دون الحاجة إلى تشغيل نموذج فيزيائي لكل منها، مما يفتح الباب أمام تحسن كبير في دقة واستقرار التوقعات، وبكلفة حسابية أقل.

نحو استبدال النموذج الفيزيائي بنماذج ذكاء اصطناعي بالكامل

أظهرت الأمثلة السابقة كيف يمكن للذكاء الاصطناعي أن يكمل النماذج الفيزيائية التقليدية لتحسين الأداء الحسابي وجودة التنبؤات الجوية. إلا أن عددًا متزايدًا من فرق البحث قد اتخذ خطوة جديدة وجريئة، تتمثل في استبدال النموذج الفيزيائي بالكامل بنموذج ذكاء اصطناعي.

في عامي ٢٠٢٢ و٢٠٢٣، تناولت سلسلة من الدراسات مسألة التنبؤ بالطقس العالمي متوسط المدى باستخدام نماذج ذكاء اصطناعي خالصة [٦]، ومن المثير للاهتمام، أن نماذج مثل Pangu-Weather وGraph Cast، التي تم تدريبها على أكثر من ٤٠ عامًا من بيانات الطقس التاريخية، أظهرت أداءً تنافسيًا في بعض الجوانب مع النموذج الفيزيائي الأوروبي ECMWF، الذي يُعتبر أفضل نموذج تشغيلي حاليًا للتنبؤ بالطقس.

وقد تم إصدار توقعات يومية عامة لهذه النماذج، ويمكن للمهتمين الاطلاع عليها عبر:

www.meteociel.fr/models/ecmwf_aifs.php
charts.ecmwf.int

ورغم أن هذه النماذج لا تزال تمثل الغلاف الجوي بشكل جزئي مقارنة بالنماذج الفيزيائية، وتواجه نقاط ضعف محددة بوضوح، إلا أنها أثبتت فعالية في التنبؤ ببعض المتغيرات الجوية، مثل: العواصف الرعدية والأعاصير المدارية، وذلك قبل عدة أيام من وقوعها [٧].

أما الميزة الكبرى لهذه النماذج، فهي الكفاءة الحسابية العالية أثناء مرحلة الاستدلال: حيث يمكن إنتاج توقعات تمتد لأيام خلال ثوانٍ أو دقائق فقط، مقارنةً بالنماذج الفيزيائية التي تحتاج إلى عشرات الدقائق أو أكثر.

التحديات المستقبلية

رغم هذا التقدم المثير، لا تزال هناك عقبات رئيسية أمام اعتماد هذه النماذج في التنبؤ التشغيلي أو في تطبيقات أخرى تعتمد على بيانات الأرصاد الجوية، من أبرزها:

تصميم نماذج مخصصة لاحتياجات المستخدمين:

يجب أن تكون هذه النماذج مدربة على بيانات عالية الدقة مكانياً، وقادرة على تمثيل المتغيرات الجوية المهمة، مع تقدير عدم اليقين المصاحب لها. وهذا يتطلب توافر مجموعات بيانات مناسبة، وموارد حوسبة ضخمة لعمليات التدريب التي قد تمتد لأسابيع.

إمكانية التفسير والتشخيص (Interpretability):

مثل النماذج الفيزيائية، فمن الضروري أن نتمكن من تحديد ما إذا كان التنبؤ جيداً لأسباب صحيحة، أو تحديد مكونات النموذج المسؤولة عن الخطأ في حالة التوقعات السيئة.

دمج المعرفة الفيزيائية في تصميم الشبكات العصبية:

إن أحد المسارات الواعدة هو تطوير ما يُعرف بالشبكات العصبية المستنيرة بالفيزياء (Physics-Informed Neural Networks)، لجعل النموذج قادراً على إنتاج حلول تتماشى مع القوانين الفيزيائية المعروفة، وبالتالي تحسين التماسك والموثوقية.

كيفية تسخير الذكاء الاصطناعي لتعزيز الخبرة البشرية في التنبؤ التشغيلي

التنبؤ التشغيلي في الأرصاد الجوية (Operational Forecasting):

هو عملية توفير تنبؤات جوية دقيقة وفي الوقت المناسب لدعم القرارات التشغيلية الفورية في مجالات مثل: الطيران، والملاحة البحرية، وإدارة الكوارث. يركز على التطبيقات العملية بدلاً من الأبحاث الأكاديمية، ويُعتبر حجر الزاوية لسلامة وكفاءة العمليات الجوية.

المكونات الرئيسية للتنبؤ التشغيلي:

Operational) (Forecasting



١ مصادر البيانات الفورية:

- تقارير الطقس التشغيلية (مثل METAR, TAF, SIGMET).
- صور الأقمار الصناعية (مثل GOES-16) والرادار (مثل NEXRAD).
- نماذج التنبؤ العددية (مثل ECMWF, GFS, WRF).

٢ النماذج التشغيلية:

- النماذج العالمية (مثل ECMWF): تغطي الكرة الأرضية بدقة ~9 كم.
- النماذج الإقليمية (مثل WRF): تركيز على مناطق محددة بدقة تصل إلى 1-3 كم.
- نماذج التخصص (متنبئات الاضطرابات الجوية، الجليد على الطائرات).

٣ أدوات التحليل:

- نظم دعم القرار (مثل EFB - Electronic Flight Bag).
- خرائط الطقس التفاعلية (مثل ADDS - Aviation Weather).

تحديات التنبؤ التشغيلي في الطيران:


- السرعة المطلوبة: تحديث التنبؤات كل ١-٦ ساعات لمواكبة التغيرات السريعة.
- الدقة المكانية: تحديد الظواهر الخطرة (مثل: الرياح القصية) بدقة عالية حول المطارات.
- التكامل مع العمليات: توصيل المعلومات للطيارين ومراقبي الحركة الجوية بشكل واضح وفّعال.
- البيانات المحدودة: في المناطق النائية (المحيطات، الصحاري) حيث تقل محطات الرصد.



تطبيقاته في الطيران:

تخطيط الرحلات (Flight Planning):

- تجنب العواصف الرعدية، الاضطرابات الجوية، والرماد البركاني.
- تحسين المسارات لتقليل استهلاك الوقود.



إدارة المطارات:

- التنبؤ بالضباب أو العواصف الرملية التي تؤثر على الرؤية.
- تخصيص مدارج الهبوط والإقلاع بناءً على اتجاه الرياح.



إدارة الأزمات:

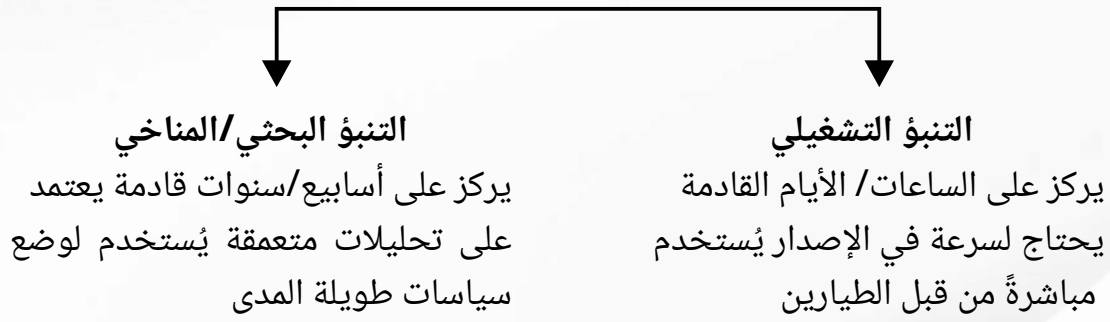
- تحذير الطائرات من الظواهر المفاجئة (مثل: Microbursts).
- إعادة توجيه الرحلات أثناء الإضرابات الجوية الكبرى.



أمثلة عملية:

- مطار دبي الدولي: استخدام نماذج WRF بدقة ١ كم للتنبؤ بالعواصف الرملية قبل ٦ ساعات.
- الخطوط الجوية الإماراتية: دمج تنبؤات الاضطرابات الجوية من ECMWF في أنظمة التخطيط.
- ناسا: أنظمة التنبؤ بالرياح القصية (Wind Shear) حول المطارات المزدحمة.

الفرق بين التنبؤ التشغيلي وأنواع التنبؤ الأخرى



أدوات وتقنيات حديثة:

- الذكاء الاصطناعي: نماذج ML للتنبؤ بالاضطرابات الجوية (مشروع Turbulence Prediction التابع لـ FAA).
- الحوسبة السحابية: معالجة البيانات عبر AWS أو Google Cloud لتسريع النماذج.
- الواقع الافتراضي: محاكاة سيناريوهات طقس متطرفة للتدريب (مثل X-Plane Weather Engine).

الاتجاهات المستقبلية:

- دمج البيانات في الوقت الحقيقي من الطائرات (مثل: Mode-S, ADS-B) لتحسين النماذج.
- التنبؤات الفائقة الدقة (Ultra-High Resolution) بدقة ٥٠٠ متر باستخدام الحواسيب الكمية.
- أنظمة إنذار آلي تعمل بالذكاء الاصطناعي لإصدار تحذيرات دون تدخل بشري.

التحديات المستقبلية:

- تأثير التغير المناخي على أنماط الطقس التقليدية.
- زيادة الضغط لتحسين الدقة مع تقليل التكاليف الحسابية.
- الحاجة إلى تدريب طواقم الطيران على تفسير تنبؤات الذكاء الاصطناعي.



الذكاء الاصطناعي والمتنبئون

رغم التقدم الكبير في نماذج التنبؤ الرقمية، سواء كانت فيزيائية أو تعتمد على الذكاء الاصطناعي، فإن إنتاج نشرات الطقس والتحذيرات ودعم اتخاذ القرار في مختلف القطاعات لا يزال يتطلب الخبرة البشرية.

مع تطور التنبؤ التشغيلي نحو مزيد من التحديثات المتكررة وتوفير التوقعات بصيغة المجموعات (Ensemble Forecasting)، أصبحت كمية البيانات التي يتعين على المتنبئين تحليلها وتفسيرها ضخمة جدًا، وفي كثير من الأحيان، في أطر زمنية ضيقة للغاية.

دور الذكاء الاصطناعي في دعم المتنبئ

يقدم الذكاء الاصطناعي فرصًا جديدة لتسهيل عمل المتنبئ، خاصة في المهام المتعلقة بما يلي:

- التعرف على الأنماط (Pattern Recognition).
- التصنيف التلقائي للمعلومات.
- تلخيص كميات ضخمة من بيانات النماذج والمراقبة.

من خلال هذه القدرات، يمكن للذكاء الاصطناعي:

- استخلاص المعلومات الأكثر صلة بسرعة من البيانات المعقدة.
- دعم اتخاذ القرار في الوقت الفعلي.
- إنتاج أدوات بصرية ذكية لتقييم المخاطر.

أمثلة تطبيقية

المثال الأول: التعرف على الهياكل الجوية (Atmospheric Structure Recognition).

لطالما اعتمدت الخبرة البشرية في الأرصاد الجوية على القدرة على تمييز البنى المفاهيمية في بيانات النماذج، مثل:

- المنخفضات الجوية.
- الأعاصير المدارية.
- الهياكل المعقدة للعواصف الرعدية.

في السابق، كان هذا العمل يتم "يدويًا" من قبل خبراء الأرصاد. لكن اليوم، يمكن للذكاء الاصطناعي بفضل قدراته المتفوقة في كشف الأجسام في الصور أن يُستخدم للتعرف تلقائيًا على مثل هذه الهياكل.



المثال الثاني: نقل التقنية من التعرف على الوجوه والقطط والكلاب إلى خرائط الطقس هو أمر مباشر.

- تُستخدم خرائط المطر والضغط والرياح كمداخلات لشبكة عصبية.
- يتم تدريبها على التعرف على هياكل جوية معينة.

شكل رقم ٥: الكشف الآلي عن "صدى القوس" (Bow Echo).


يُظهر الشكل ٥ نتائج نموذج ذكاء اصطناعي مُدرَّب على الكشف عن نوع عنيف من العواصف الرعدية يُعرف باسم "صدى القوس"، وهي بنية جوية على شكل قوس مصحوبة برياح مدمرة.

تجميع نتائج هذه الاكتشافات من عدة توقعات يمكن أن:

- يولّد مؤشرات احتمالية لحدوث الحدث.
- يدعم أدوات الإنذار المبكر.
- يساعد في القرارات الحساسة للزمن [٨].

من الاستخدامات المتقدمة للذكاء الاصطناعي في التنبؤ التشغيلي، تبسيط مجموعة واسعة من التوقعات العددية من خلال:

- تجميع المعلومات من عشرات التوقعات (كما في تنبؤات المجموعات - Ensemble Forecasts).
- إنتاج عدد محدود من السيناريوهات التمثيلية التي تُعرض على المتنبئين والمستخدمين النهائيين.



التصنيف التلقائي للسيناريوهات التنبؤية (شكل ٥).

السيناريوهات الناتجة عن الذكاء الاصطناعي تشمل:

- السيناريو الأكثر احتمالاً: الذي يظهر بشكل متكرر أو غالب في التوقعات المختلفة.
- السيناريوهات البديلة: أقل احتمالاً ولكنها مهمة نظراً لارتباطها بمخاطر عالية أو ظروف جوية قاسية، ولا يمكن تجاهلها بسبب عدم اليقين.

الأسلوب المستخدم: التصنيف التلقائي (Automatic Clustering).

يعتمد الذكاء الاصطناعي هنا على خوارزميات التصنيف التلقائي (مثل: K-means أو خوارزميات التعلم غير الموجه)، التي:

- تقوم بتجميع التوقعات المتشابهة في مجموعات فكرية أو سيناريوهات.
- تساعد المتنبئين على استخلاص الاتجاهات الرئيسية من مجموعة واسعة من المخرجات.

الذكاء الاصطناعي واتصالات توقعات الطقس:

يُنظر إلى الذكاء الاصطناعي (AI) اليوم ليس فقط كأداة حسابية متقدمة تستخدم في النمذجة أو التحليل، بل كوسيلة قد تُحدث ثورة في طريقة التواصل بين خدمات الأرصاد الجوية والمستخدمين.

تغيير نمط الاتصال:

- في السابق، كانت التوقعات الجوية تُبث للمستخدمين بشكل أحادي الاتجاه (من الخبير إلى الجمهور). أما اليوم، فإن أدوات الذكاء الاصطناعي تمكن من:
- الوصول التفاعلي للمعلومة الجوية.
- تخصيص التوقعات حسب الطلب المباشر من المستخدم.
- دمج الذكاء الاصطناعي في تطبيقات الهاتف المحمول لإنتاج تقارير جوية آلية (مثل: إشعارات الطقس المخصصة).

هل يمكن للذكاء الاصطناعي أن يحل محل مذيعي الطقس؟

بدأت بعض الدول بالفعل اختبار هذا المفهوم، ومن أبرز الأمثلة: سويسرا: قامت بتقديم أول مذيع طقس افتراضي يعمل بالذكاء الاصطناعي، يتحدث إلى الجمهور بطريقة طبيعية ومحاكية للبشر.

الواقع والمستقبل:

- رغم أن هذه التقنيات لا تزال في مراحلها الأولى، إلا أن مميزاتها التفاعلية والتخصيصية قد تؤدي إلى:
- إعادة تعريف العلاقة بين المستخدم والمعلومة الجوية.
- تحويل المستخدم من "متلقٍ سلبي" إلى "مشارك في تحديد نوع المعلومات التي يحتاجها".
- إنشاء معايير جديدة للتواصل الأرصادي تستند إلى الذكاء الاصطناعي.

المصادر :

- 1- Le Cun, Y., L. Bottou, Y. Bengio, and P. Haffner, 1998: التعرف على التدرج المطبق على التعرف على المستندات. وقائع معهد مهندسي الكهرباء والإلكترونيات، 86، 2324-2278
- 2- Taillardat, M., A. Fougères, P. Naveau, and O. Mestre, 2019: Forest-Based and Semiparametric Methods for the Postprocessing of Rainfall Ensemble Forecasting. Wea. Forecasting, 34, 617–634, <https://doi.org/10.1175/WAF-D-18-0149.1>
- 3- بالوغ ب.، 2022. حول استخدام الذكاء الاصطناعي في نموذج رقمي للمناخ. الدكتوراه في المحيط والغلاف الجوي والمناخ. تولوز INPT.
- 4 - Doury, A., Somot, S., Gadat, S. et al. Regional climate model emulator based on deep learning: concept and first evaluation of a novel hybrid downscaling approach. Clim Dyn 60, 1751–1779 (2023). <https://doi.org/10.1007/s00382-022-06343-9>
- 5 - Brochet, C., L. Raynaud, N. Thome, M. Plu, and C. Rambour, 2023: محاكاة متعددة المتغيرات للتنبؤات الجوية الرقمية على مقياس الكيلومتر باستخدام الشبكات التنافسية التوليدية: إثبات المفهوم. Artif. Intell. Earth Syst., 2, 230006, <https://doi.org/10.1175/AIES-D-23-0006.1>.
- 6- القنسات، رضوان. النماذج الجديدة لتوقعات الأرصاد الجوية المستندة إلى الذكاء -lamétéologue-2023 الاصطناعي: فرصة أم تهديد؟. الأرصاد الجوية، 121، 11-15، 2023. 10.37053-0030
- 7- باردي، م.، ل. راينود، أ. مونييه، 2024: التنبؤ متوسط المدى للعاصفة سياران باستخدام الذكاء الاصطناعي. الأرصاد الجوية.
- 8- Mounier, A., L. Raynaud, L. Rottner, M. Plu, P. Arbogast, M. Kreitz, L. Mignan, and B. Touzé, 2022: اكتشاف أصداء القوس في التنبؤات على مقياس الكيلومتر باستخدام شبكة عصبية ملتوية. Artif. Intell. Earth Syst., 1, e210010, <https://doi.org/10.1175/AIES-D-21-0010.1>.

