



النمذجة التنبؤية لتركيزات PM10 في مدينة الرياض باستخدام التقنيات الجيومكانية وخوارزميات التعلم الآلي

أ.د. ذكى عبدالجليل على سلام

الجغرافية، العلوم الإنسانية والاجتماعية، جامعة الملك سعود، الرياض، المملكة العربية السعودية

البريد الإلكتروني: thikra111@hotmail.com

د. محمد السيد حافظ

الجغرافية، العلوم الإنسانية والاجتماعية، جامعة الملك سعود، الرياض، المملكة العربية السعودية

البريد الإلكتروني: mohhafez@ksu.edu.sa

الملخص

يمثل تلوث الهواء الحضري تحدياً كبيراً يؤثر سلباً على جودة البيئة، والصحة العامة، والتنمية الاقتصادية، والإدارة الشاملة للمناطق الحضرية. ومن بين مختلف الملوثات، تُعدّ الجسيمات الدقيقة (PM₁₀) من أبرز ملوثات الهواء التي تشكل خطراً على الصحة، لا سيما في المراكز الحضرية الكبرى بمدينة الرياض. ونظراً للتغيرات الموسمية في تراكم PM₁₀، تبرز الحاجة إلى إجراء نمذجة زمانية-مكانية وتحديد المناطق عالية الخطورة لدعم استراتيجيات التخفيف وتقليل الآثار الصحية.

هدفت الدراسة إلى نمذجة التوزيع المكاني والزمني لـ PM₁₀ وإنتاج خرائط المخاطر في مدينة الرياض باستخدام أربع خوارزميات للتعلم الآلي في بيئة البرمجة python: الغابة العشوائية (Random Forest)، وتعزيز التدرجي الفائق (RF)، وتعزيز التدرجي الفائق (Extreme Gradient Boosting- XGBoost)، ومتعدد الأقرب (k-Nearest neighbors- k-NN)، آلة المتجهات الداعمة (Support Vector Machine - SVM)، وتم حساب المتوسطات الموسمية لتركيزات PM₁₀ لفصل الشتاء، الربيع، الصيف، الخريف، لتشكيل المتغير التابع. كما تم إدراج مجموعة من المتغيرات المستقلة المستمدة من بيانات الاستشعار عن بعد ونظم المعلومات الجغرافية، وشملت: معدلات درجة الحرارة، الرطوبة النسبية، سرعة الرياح، كمية الأمطار، العواصف الغبارية، مؤشر الغطاء النباتي المعدل للتربيه، مؤشر المناطق المبنية والأراضي العاربة المحسّن، كثافة السكان، كثافة شبكة الطرق، والمسافة إلى المناطق الصناعية. وقد تم تجميع هذه المتغيرات على المستوى الموسمي أيضاً. وقد حققت خوارزمية الغابة العشوائية وتعزيز التدرجي الفائق أعلى دقة تنبؤية، حيث بلغت قيمة AUC لخوارزمية الغابة العشوائية: 0.921، 0.986، 0.961، 0.994 لفصل الشتاء، الربيع، الصيف، والخريف على التوالي، بينما بلغت قيمة AUC لخوارزمية التعزيز التدرجي الفائق: 0.911، 0.963، 0.985، 0.994 لفصل الشتاء، الربيع، الصيف، والخريف على التوالي.

كما أشارت النتائج إلى أن أعلى مخاطر التعرض لـ PM₁₀ وفقاً لنموذجي الغابة العشوائية وتعزيز التدرجي الفائق كانت في فصل الصيف والخريف بالتساوي، ثم الربيع، وأخيراً الشتاء. وفي فصول وتوارد هذه النتائج فعالية نماذج التعلم الآلي في التقاط ديناميكيات التلوث الموسمي، كما تقدم أدوات قيمة لإدارة جودة الهواء في البيئات الحضرية.

الكلمات المفتاحية: تلوث، جودة الهواء، الجسيمات الدقيقة (PM10)، النمذجة المكانية والزمانية، البيانات المستقلة والتابعة.



Predictive Modeling of PM₁₀ Concentrations in Riyadh City Using Geospatial Technologies and Machine Learning Algorithms

Dhikra Abdul-Jalil Ali Sallam

Geography, Humanities and Social Sciences, King Saud University, Riyadh, Saudi Arabia

Email: thikra111@hotmail.com

Dr. Mohamed El-Sayed Hafez

Geography, Humanities and Social Sciences, King Saud University, Riyadh, Saudi Arabia

Email: mohhafez@ksu.edu.sa

ABSTRACT

Urban air pollution poses a significant challenge, adversely affecting environmental quality, public health, economic development, and the comprehensive management of urban areas. Among various pollutants, particulate matter (PM₁₀) stands out as one of the most critical air pollutants due to its health risks, particularly in major metropolitan centers such as Riyadh. Given the seasonal fluctuations in PM₁₀ concentrations, there is a pressing need for spatiotemporal modeling and the identification of high-risk areas to support mitigation strategies and minimize health impacts. The study aimed to model the spatiotemporal distribution of PM₁₀ and generate risk maps for Riyadh using four machine learning algorithms within a Python programming environment: Random Forest (RF), Extreme Gradient Boosting (XGBoost), k-nearest neighbors (k-NN), and Support Vector Machine (SVM). Seasonal averages of PM₁₀ concentrations were calculated for winter, spring, summer, and autumn to serve as the dependent variable. A set of independent variables, derived from remote sensing and geographic information systems (GIS) data, was incorporated. These included temperature rates, relative humidity, wind speed, precipitation, dust storm frequency, Soil-Adjusted Vegetation Index (SAVI), Enhanced Built-up and Bare Land Index (EBBI), population density, road network density, and distance to industrial areas. These variables were also aggregated at the seasonal level. The findings further indicated that the highest risk of PM₁₀ exposure, as predicted by both the Random Forest and XGBoost models, occurred during summer and autumn (equally), followed by spring, with winter presenting the lowest risk levels. These results underscore the effectiveness of machine learning models in capturing the seasonal dynamics of pollution and offer valuable tools for air quality management in urban environments.

Keywords: Pollution, Air Quality, Fine Particulate Matter (PM10), Spatio-temporal Modeling, Independent and Dependent Data.



أهداف الدراسة

يتمثل هدف الدراسة الرئيس في تطوير وتقييم نماذج تنبؤية لمخاطر تركزات PM_{10} في مدينة الرياض باستخدام خوارزميات التعلم الآلي والبيانات البيئية الجغرافية المكانية، مع التركيز على التوزيع المكاني والتغيرات الموسمية، ومن ثم تتضمن الأهداف الفرعية للدراسة، فيما يلى:

- 1- تقييم التباين المكاني والزمني لتركيزات PM_{10} في الرياض خلال الفترة من 2017 إلى 2021 عبر الموسام المختلفة، باستخدام تقييمات الاستيفاء المكاني وإعداد الخرائط.
- 2- تحديد العلاقة بين العوامل المؤثرة ومستويات تركز PM_{10} ، والمتغيرات الجيومكانية الأكثر تأثيراً في توزيع PM_{10} ، ضمن إطار التعلم الآلي.
- 3- بناء ومقارنة نماذج تعلم آلي متعددة للتنبؤ بتركيزات PM_{10} بالاعتماد على البيانات الجيومكانية.
- 4- تقييم تأثير التغيرات الموسمية على دقة النماذج التنبؤية المطورة، وتحديد الفترات الزمنية التي تمثل تحديات أكبر في التنبؤ بمستويات التلوث.
- 5- توليد توصيات قائمة على البيانات يمكن أن تدعم صانعي القرار في إدارة جودة الهواء وتطوير سياسات الصحة العامة في البيئات الحضرية الجافة كالرياض، من خلال النماذج التنبؤية الأنسب ورسم خرائط المخاطر المكانية.

أهمية الدراسة

لا يزال تلوث الهواء الحضري يمثل تحدياً جوهرياً أمام تحقيق التنمية المستدامة، والصحة العامة، والعدالة البيئية. ففي مدينة الرياض، تتجاوز تركيزات الجسيمات الدقيقة PM_{10} الحدود الإرشادية التي وضعتها منظمة الصحة العالمية ومجلس التعاون الخليجي ووزارة البيئة والمياه والزراعة في المملكة العربية السعودية، مع تناول مكاني ملحوظ في توزيع التلوث بين الأحياء. وفي ظل تزايد التحديات البيئية والصحية المرتبطة بتلوث الهواء، يصبح وجود نموذج كأدلة إنذار مبكر دقيق وموثوق أمراً بالغ الأهمية لحماية السكان، ومع ذلك، فإن الأدبيات القائمة تعتمد بشكل رئيسي على محطات الرصد الثابتة ونماذج إحصائية تقليدية، وهي أدوات محدودة في قدرتها على تمثيل التغير المكاني – الزمانى الدقيق في التعرض للتلوث. كما أن عدد قليل فقط من الدراسات قام بتطبيق تقييمات التعلم الآلي ضمن إطار جيومكاني للتنبؤ بمخاطر PM_{10} ، في بيئات مختلفة، وأقل منها من تناول هذا التكامل في السياق الحضري الخليجي، ومن ثم تسعى الدراسة إلى سد هذه الفجوات من خلال تطبيق ومقارنة نماذج تعلم آلي تجميعي مدعومة بتحليل مكاني ثانوي المتغير، بهدف تقديم تقييم عالي الدقة لمخاطر PM_{10} في جميع أنحاء مدينة الرياض.

وبناءً عليه، تقدم الدراسة مساهمة نظرية من خلال دمج خوارزميات التعلم الآلي مع أدوات التحليل المكاني بهدف تطوير نماذج بيئية حضرية أكثر تقدماً. وتحتوى هذه المقاربة الأساليب التقليدية في نماذج تلوث الهواء التي اعتمدت فقط على النماذج الحتمية أو الإحصائية، عبر إثبات فعالية التعلم الآلي في التقاط التفاعلات غير الخطية المعقدة بين المتغيرات البيئية النفسية المحلية وتركيز مستويات PM_{10} . علاوة على ذلك، تقدم الدراسة إطاراً منهجياً يربط بين نماذج البيانات البيئية ونظرية الاستدامة الحضرية، مسهمة في إثراء الإنتاج العلمي متعدد التخصصات في مجالات تحليلات المدن الذكية والعدالة البيئية المكانية. علاوة على ذلك، يدمج العمل تقييمات التحليل المكاني الثنائي (نسبة التكرار FR - Frequency Ratio) لاختيار المتغيرات التنبؤية وتحديد أوزانها، مما يعزز من شفافية النماذج وكفاءتها التنبؤية. بالإضافة إلى ذلك، فإن عملية التقييم المقارن لأداء النماذج تعزز من فهم الباحثين المستقبليين لأليات اختيار النماذج وتحليل موثوقيتها ودققتها في الأنظمة الحضرية المعقدة وفي ظروف جغرافية وبيئية متغيرة. ومن ثم تُسهم الدراسة في تلبية الطلب الأكاديمي المتزايد على تطبيقات التعلم الآلي في العلوم البيئية، من خلال تقديم نموذج قابل للتكرار يمكن اعتماده في مدن أخرى تواجه تحديات مماثلة.



وعلى مستوى التطبيقات العملية تقدم الدراسة نتائج ذات قيمة تطبيقية عالية يمكن تسخيرها من قبل الجهات المعنية بالتحطيط الحضري، والإدارة البيئية، والصحة العامة، مما يعكس أثراً مباشراً ولموسعاً يتجاوز الإسهام النظري. فعلى مستوى الحكومات المحلية والمخططين الحضريين، توفر الدراسة أدوات تحليل مكانية دقيقة يمكن توظيفها في تقييم الأثر البيئي للمشروعات التنموية الكبرى، وتقييم دلائل استرشادية مبنية على بيانات مكانية لتجويه قرارات تخطيط المدن، لاسيما في سياق تصميم استراتيجيات التحكم في الانبعاثات ضمن المناطق المعرضة لمستويات عالية من تلوث الهواء بالجسيمات الدقيقة PM₁₀. كما تشكل النتائج مرجعاً علمياً يمكن وكالات إدارة جودة الهواء من الوصول إلى أدوات بديلة فعالة ومنخفضة التكلفة، تكمل شبكات الرصد الميداني التقليدية، لا سيما في المدن التي تتسم بتضاريس غير متGANSAة ومتعددة في مصادر التلوث (كالازدحام المروري، والأنشطة الصناعية). ويكتسب هذا البعد أهمية متزايدة مع محدودية تغطية المحطات التقليدية للرصد في مناطق حضرية معقدة كما هو الحال في الرياض. وهنا، يؤدي التموذج المقترن دوراً محورياً كأدلة استرشادية قادرة على إنتاج خرائط خطر عالية الدقة للتلوّث لـ PM₁₀، ثُمّزه بوضوح النقاط الساخنة للتلوث في أنحاء المدينة، مما يُمكّن الجهات المعنية من التدخل في الوقت المناسب.

أما على صعيد السلطات الصحية العامة، فإن الدراسة تمثل نقلة نوعية في دعم الانتقال من نماذج التدخل القائمة على "المعالجة اللاحقة" إلى استراتيجيات قائمة على "الاستجابة الاستباقية". ومن خلال النتائج التفصيلية التي تحدد الأحياء ذات التعرض المرتفع للتلوث الهواء، يمكن للجهات الصحية استهداف التدخلات المجتمعية بشكل أكثر فاعلية، وتطوير حملات توعية موجهة للسكان حول المخاطر البيئية والصحية المرتبطة بالجسيمات الدقيقة، بما يساهم في تعزيز الوقاية وتقليل معدلات الأمراض المرتبطة بالتلوث الهوائي. حيث توفر خرائط مخاطر PM₁₀ عالية الدقة التي تنتجهها المنفذة إطاراً تطبيقياً ثرياً يمكن توظيفه في عدة جوانب عملية، من بينها:

- تحديد المواقع المناسبة لتوسيع أو إنشاء مناطق الانبعاثات المنخفضة (Low Emission Zones).
- دعم فرض قيود أكثر صرامة على مصادر الانبعاثات الصناعية في المناطق الحساسة.
- تصميم مشاريع البنية التحتية الخضراء مثل الأحزنة النباتية أو المساحات الحضرية المستدامة.
- إعادة تخطيط مسارات المرور لتقليل التعرض للتلوث في الأحياء السكنية.
- توجيه التدخلات الصحية والبيئية استناداً إلى بيانات قابلة التنفيذ على مستوى الحي الإداري.

كما تُسهم هذه البيانات في تعزيز قدرة السلطات المحلية على تنفيذ برامج عمل فاعلة، مثل بروتوكول العمل للحد من تلوث الهواء في مدينة الرياض أو مشروع "موجة الرياض الخضراء". كما يتميز الإطار المقترن بمرونة عالية وإمكانية تكييفه وتطبيقه في مدن أخرى ضمن مبادرات إدارة جودة الهواء في العالم العربي والعالمي على حد سواء. علاوة على ذلك، تعالج هذه الدراسة قضايا مجتمعية ملحة تتعلق بالعدالة البيئية والصحة العامة، إذ تسلط الضوء على التفاوتات المكانية في توزيع التعرض للتلوث الهواء، ما يُعد أساساً لتطوير سياسات حضرية أكثر إنصافاً وشمولًا. فهي تدعم جهود الجهات الصحية والمجتمعية في تقليل الفجوات الصحية المرتبطة بالعوامل البيئية، وتسهم في دعم تخطيط حضري يرتكز إلى مبادئ الاستدامة والعدالة البيئية.

وباختصار، تحوّل هذه الدراسة المعتقدات العلمية المرتبطة بتلوث الهواء إلى أدوات تطبيقية عملية قابلة للتنفيذ، وتجسد كيفية تسخير التقنيات الحديثة، من خلال التكامل بين التعلم الآلي والتحليل المكاني، لخدمة الصحة العامة والاستدامة البيئية في المدن المعاصرة. إنها تجعل "ما هو غير مرئي مرئياً"، وتترجم التعقيد العلمي إلى وضوح استراتيجي يدعم القرار ويحدث الأثر.

ونقع الدراسة عند تقاطع ثلاثة مجالات حيوية: الذكاء الاصطناعي الجغرافي، والعلوم البيئية الحضرية، والسياسات العامة. ومن خلال ذلك، تُسهم في الخطاب المتنامي حول كيفية تسخير المدن للبيانات من أجل تنمية مستدامة وعادلة. كما تدعم هذه الدراسة التحول نحو تخطيط حضري قائم على الأدلة، وتتوافق مع الدعوات الدولية للتحول الرقمي في الحكومة البيئية. وتشير النقاشات الأكاديمية حول تحليل المخاطر المكانية، وإعداد خرائط التلوث، وتطبيق أدوات الذكاء الاصطناعي في أبحاث العدالة البيئية. وعلى الرغم من أن الدراسة تقدم



إطاراً متنبياً لتقدير مخاطر PM₁₀ في الرياض، إلا أنها تفتح آفاقاً واعدة لمزيد من البحث، منها: تطبيق النموذج على ملوثات أخرى PM_{2.5} أو NO₂، ودراسة المخاطر الناتجة عن التعرض المشترك، دمج بيانات الاستشعار الآلي من الأقمار الصناعية وأجهزة الاستشعار الأرضية لتقديم تنبؤات ديناميكية، إجراء دراسات على الأمد الطويل تربط بين التعرض للتلوث والتنتائج الصحية عبر الأبعاد المكانية والزمانية، وتحليل الاستجابات السوسنولوجية والسلوكية للبيانات المكانية المتعلقة بالتلوث الحضري. من شأن هذه المسارات أن تعمق من أثر هذا العمل، وتتوسّع نطاق استخدامه في أبحاث أوسع حول البيئة والصحة العامة.

وباختصار، تكمن أهمية هذه الدراسة في قدرتها على التعرف الدقيق على مشكلة واقعية، وتقديم حل تقني مبتكر ومدقق، وربط نتائجها بالسوق المجتمعي الأوسع. فهي تمثل تقدماً علمياً ذا مغزى في فهم تلوث الهواء الحضري، وتتوفر أدوات عملية لتحسين المرونة الحضرية، والصحة العامة، وتحقيق العدالة البيئية.

الدراسات السابقة:

تُعد نمذجة تلوث الهواء أداة عملية وأساسية لتوقع وتقدير التوزيع المكاني والزمني للملوثات الجوية. وُتستخدم هذه النماذج على نطاق واسع لمحاكاة أنماط انتشار الابتعاثات وتقييم آثارها على صحة الإنسان، وجودة البيئة، والأداء الاقتصادي (Rybarczyk & Zalakeviciute, 2018)، وتحتَّم هذه القدرة التنبؤية عنصراً محورياً في إدارة البيئة بشكل استباقي، وفي صياغة مبادرات الصحة العامة. علاوة على ذلك، فإن إتاحة التوقعات المتعلقة بجودة الهواء بشكل شفاف للجمهور تُسهم في تعزيز الوعي المجتمعي. فعندما يكون المواطنون على دراية بحالة الهواء الراهنة والمُتوقعة، فإن ذلك يُشجّعهم على المشاركة الفاعلة في الجهود الرامية إلى تقليل التلوث، بما يعزّز فعالية التدخلات البيئية على مستوى المجتمع بأكمله (Shogrhodaei et al., 2021).

وفي الوقت الراهن، وبفضل انتشار محطات الرصد الأرضية في مناطق مختلفة من المدن، تُقاس تراكمت الملوثات بدقة مقبولة (Ghaemi, Alimohammadi, & Farnaghi, 2018)، إلا أن من أبرز المشكلات المرتبطة بهذه المحطات هو محدوديتها وتوزيعها غير المنتجنس، مما يُقيّد القدرة على تغيير الملوثات على نطاق جغرافي واسع وبشكل متواصل، ويحول دون إعداد خرائط مستمرة لمخاطر التلوث. ففي المدن الكبرى أو المناطق ذات التضاريس المتنوعة، يمكن أن تختلف مستويات التلوث بشكل كبير خلال مسافات قصيرة بسبب اختلاف مصادر الابتعاثات المحلية، وكثافة حركة المرور، والظروف الجوية. ومع ذلك، غالباً ما تعجز المحطات الثابتة عن التقاط هذا التباين المكاني الدقيق. فعلى سبيل المثال، أظهرت دراسة أجريت في مدينة أصفهان، إيران، أن الاعتماد الحصري على المحطات الأرضية أخفى العديد من بؤر التلوث الدقيقة لجسيمات PM_{2.5}، بينما أدى دمج وحدات استشعار متنقلة مع المحطات التقليدية إلى تحسين دقة نماذج جودة الهواء بنسبة تجاوزت 60% (Haghbayan & Tashayo, 2021). وتزداد حدة هذه التحديات في البيئات الجافة وشبه القاحلة، حيث تتأثر مستويات PM₁₀ بشكل كبير بإعادة تعليم الغبار الطبيعي، والرياح الصحراوية، وأنماط استخدام الأرضي. وتعُد هذه الظروف قدرة المحطات الأرضية على رصد أحداث التلوث اللحظية، خاصةً عندما يكون توزيع المحطات قليل الكثافة. كما أن مصادر الجسيمات في هذه المناطق غالباً ما تكون مزدوجة؛ إذ تتبع من كلٍ من المصادر البشرية (مثل المرور والصناعة) والمصادر الطبيعية (كالغبار المحمول بالرياح)، مما يصعب من مهام تحديد مصادر التلوث وتقييم المخاطر البيئية. فعلى سبيل المثال، كشفت دراسة أجريت في مناخ البحر الأبيض المتوسط، مثل مدينة أثينا اليونانية، أن دقة القياسات تأثرت سلباً بظروف الطقس الجاف، وترافق الغبار على أجهزة الرصد، ودرجات الحرارة المرتفعة، مما أظهر الحاجة إلى إعادة معايرة متكررة لهذه الأجهزة (Christakis, Stavrakas, Hloupis, & Tsakiridis, 2020).

ويمكن من خلال استخدام نظم المعلومات الجغرافية وتقييمات الاستشعار عن بعد ، تحليل التغيرات والأنماط المكانية والزمانية لانتشار تلوث الهواء بكفاءة وتكلفة ووقت منخفضين (Sudhira et al., 2003)، حيث تتيح نظم المعلومات الجغرافية تطبيق أساليب الاستيفاء لدراسة التوزيع المكاني للملوثات، إلى جانب إدارة البيانات المكانية وأخذ تأثير عوامل النمذجة الفعالة بعين الاعتبار (Mozumder et al., 2013)، ومن جهة أخرى تُكمل تقييمات الاستشعار عن بعد دور نظم المعلومات الجغرافية، حيث تُعد تقييمات الاستشعار عن بعد أدلة فعالة لمراقبة الظواهر المتغيرة على سطح الأرض وإدارتها زميّناً (Sohrabinia & Khorshidoust, 2007).



فالمجسات الفضائية مثل MODIS و Landsat ترصد مؤشرات قيمة مثل السماكة البصرية للهباء الجوي (AOT) rosol optical thickn ess (AOT)، ودرجة حرارة سطح الأرض، وتوقعات ملوثات ترتبط ارتباطاً وثيقاً بتراكيز ملوثات الهواء عند مستوى السطح مثل الجسيمات الدقيقة (PM)، وأكسيد النيتروجين، وأول أكسيد الكربون. وقد أظهرت الدراسات أن بيانات AOT المستخلصة من الأقمار الصناعية وبيانات الأشعة تحت الحمراء الحرارية ترتبط بشكل كبير بقياسات الأرض الخاصة بـ $PM_{2.5}$ و PM_{10} والكربون الأسود، مما يعزز التغطية المكانية والدقة في خرائط تلوث الهواء (Wijeratne & Bijker, 2006).

وتعُد دراسة زوران وزوران (Zoran & Zoran, 2005) من أوائل الجهود المؤثرة التي سعت إلى دمج تقنيات الاستشعار عن بعد مع بيانات الرصد الميداني (in-situ monitoring) لرسم خرائط ثلاثة الأبعاد (3D) لتوزيع تلوث الهواء الحضري. فعلى الرغم من أن أساليب الذكاء الاصطناعي وتعلم الآلة لم تكن قد ترسخت بعد في هذا المجال، فقد أثبتت هذه الدراسة قاعدة معرفية مبكرة من خلال إثبات إمكانية الاستفادة من صور الأقمار الصناعية، ومنها: TM، ETM، Landsat TM، SPOT، MODIS، إلى جانب البيانات المناخية الأرضية، عبر نماذج حيوية بصرية (linear regression)، وانحدار الخطى (bio-optical modeling) (Aerosol Optical Thickness)، لتقدير تركيزات الملوثات الجوية وتحليل سلوكها المكاني. وقد تحورت الدراسة حول العاصمة الرومانية بوخارست، حيث ركز الباحثان على دور سُمك الهباء البصري (Aerosol Optical Thickness) في تشكيل أنماط انتشار التلوث. وقد أبرزت النتائج وجود علاقات ارتباط إحصائية قوية بين أطوال موجية مُشتقة من صور الأقمار الصناعية (وخاصة النطاقات الأخضر، والأحمر، وتحت الأحمر الحارسي) وتركيزات المواد الجسيمية (Particulate Matter)، والكربون الأسود، وأول أكسيد الكربون. ما مثل آنذاك دليلاً جوهرياً على إمكان استخدام بيانات الفضاء في تقييم جودة الهواء. وباختصار، أسهمت الدراسة في ترسیخ الأسس العلمية لاستخدام الاستشعار عن بعد في رصد جودة الهواء في المدن، ولا تزال تُعد مرجعاً أساسياً لفهم كيف ساهمت الأساليب الجيومكانية التقليدية في تمهيد الطريق نحو التطورات الحالية في تمنجة جودة الهواء. حيث شكلت حجر الأساس الذي بُنيت عليه التطبيقات المعاصرة في مجال التمنجة الجغرافية البيئية. فهي من أوائل الدراسات التي أثبتت أن الإشارات الطيفية الحرارية والبصرية الملقطة بالأقمار الصناعية يمكن أن ترتبط ارتباطاً معنوياً بتركيزات الملوثات الأرضية.

وتمثل الدراسة التي أجرتها جوهير وأخرون (Goheer et al., 2025) خطوة متقدمة ومهمة في فهم ديناميكيات الضباب الدخاني ومصادر تلوث الهواء في جنوب آسيا. وبينما ربطت الدراسات السابقة ارتفاع مستويات التلوث في باكستان بالتوسيع الحضري والانبعاثات الناتجة عن المركبات واحترق الكتلة الحيوية، تميزت دراسة جوهير باستخدام مجموعات بيانات جيومكانية مدمجة - شملت بيانات الأقمار الصناعية من MODIS ، ونمذاج إعادة التحليل من MERRA-2 ، ونظام تتبع الجسيمات HYSPLIT - مما مكّن الباحثين من رسم خريطة دقيقة لاتجاهات الملوثات على المستويين الزماني والمكاني. وقد أكدت نتائج الدراسة ما توصلت إليه أبحاث سابقة بخصوص اعتبار مدیني لا هور وفيصل آباد نقاطاً ساخنة للتلوث، لكنها تجاوزت ذلك عبر تقديم كميات دقيقة لأنبعاثات الجسيمات الدقيقة ($PM_{2.5}$) الموسمية، وتسلیط الضوء على مساهمة متزايدة لمناطق ريفية مثل حافظ آباد وناروال في هذا التلوث، نتيجة ممارسات مثل حرق بقايا المحاصيل الزراعية.

وفي دراسة أجراها نغوين وأخرون (Nguyen et al., 2025)، قدم الباحثون تحليلًا جيومكانياً شاملًا للتلوث الهباء في محافظة دونغ ناي الفيتنامية، مع التركيز على التغيرات الموسمية ومصادر التلوث خلال الفترة الممتدة من عام 2022 إلى عام 2023. قام الفريق البحثي برصد جودة الهواء في 55 موقعًا مختلفًا، حيث تم قياس تركيز كل من الجسيمات العالقة الكلية (TSP)، وأ ثاني أكسيد الكبريت (SO_2)، وأ ثاني أكسيد النيتروجين (NO_2)، وأ أول أكسيد الكربون (CO) خلال موسمي الجفاف والمطر. وقد تم تمثيل هذه القياسات مكانيًا باستخدام أدوات نظم المعلومات الجغرافية (GIS) وتقنية الوزن العكسي للمسافة (IDW) – Inverse Distance Weighting لتصوير شدة التلوث وتوزيعه الجغرافي. أظهرت النتائج وجود تأثير موسمي واضح على تركيزات الملوثات، حيث سُجّل كل من TSP و NO_2 مستويات تجاوزت باستمرار الحدود السنوية التي يحددها المعيار الوطني الفيتنامي لجودة الهواء، لا سيما خلال مواسم الجفاف، مع ملاحظة اتجاه تصاعد في هذه التراكيز على



مدار عامين. وقد بلغت أعلى قراءة لـ TSP (202.53 ميكروغرام/م³) في مناطق معالجة النفايات خلال موسم الجفاف لعام 2023، في حين سُجل أدنى ترکیز (25.21 ميكروغرام/م³) في مناطق الظهير خلال عام 2022. أما NO₂، فقد كانت تراكيزه مرتفعة بوجه خاص في المناطق السكنية، بينما وصلت تراكيز CO إلى ذروتها في المناطق القريبة من المطارات (6126.15 ميكروغرام/م³ في عام 2023)، وانخفضت بشكل ملحوظ في مناطق النفايات خلال موسم الأمطار (100.00 ميكروغرام/م³). ومن النتائج اللافتة في الدراسة، وجود ارتباط قوي بين تراكيز CO ومستويات التلوث الضوضائي (معامل ارتباط $r = 0.90 < 0.01$, p), ما يشير إلى علاقة مباشرة بحركة المرور والنشاط البشري اليومي. في المقابل، لم يُسجل أي ارتباط معنوي بين المؤشرات الأخرى. وتؤكد هذه النتائج أن الأنشطة اليومية — وعلى رأسها التنقل المروري — تعدّ المساهم الرئيسي في تلوث الهواء المحلي بمحافظة دونغ ناي.

علاوة على ذلك، تم توظيف أنظمة متكاملة تجمع بين نظم المعلومات الجغرافية والاستشعار عن بعد بنجاح لتتبع ديناميكيات تلوث الهواء عبر الزمن. فعلى سبيل المثال، تقدم المراجعة التي أعدّها تيكادير، موكوبادي، وإسلام (Tikader, Mukhopadhyay, & Islam, 2023) تحليلًا ترکيبيًا عميقًا حول الكيفية التي يمكن من خلالها توظيف تقنيات الاستشعار عن بعد ونظم المعلومات الجغرافية كأدوات محورية لرصد تلوث الهواء، ونمذجته، والتخفيف من آثاره، وبوجه خاص فيما يتعلق بالملوثات الجسيمية (Particulate Matter - PM) في الهند. ويُشير الباحثون إلى أن الأنشطة الصناعية، ووسائل النقل، والتعدّين، وحرائق الغابات، والانبعاثات المنزليّة، تعدّ من أبرز مصادر الجسيمات الملوثة في الهند، خصوصاً في المناطق الحضرية، ما يشكّل تهدّياً حادّاً للصحة العامة. وتبّرر المراجعة كيف تم توظيف تقنيات الاستشعار عن بعد ونظم المعلومات الجغرافية بنجاح في: رسم خرائط للبؤر الساخنة للتلوث (Pollution Hotspots)، التنبؤ بأنماط توزيع الجسيمات الدقيقة، تتبع مصادر الانبعاثات، وتقدير مستويات التعرض البيئي على مستوى المجتمعات المحلية، وتعزّز هذه المراجعة أهمية الاستشعار عن بعد ونظم المعلومات الجغرافية في حوكمة جودة الهواء، وتدعى إلى تكاملها المنهجي مع بيانات المناخ والصحة العامة من أجل تعظيم فائدتها في جهود الحد من التلوث وحماية الصحة المجتمعية.

في دراسة أجراها تيكادير وموكوبادي ودابهادكار (Tikader, Mukhopadhyay, & Dabhadkar, 2024)، تناول الباحثون تحديات تلوث الهواء في ولاية تاشاتيسغره الصناعية بالهند وثّعد أكثر الولايات الهندية ترکيزاً في النشاط الصناعي وتواجهه مستويات مرتفعة من تلوث الهواء ، عبر دمج تقنيات الاستشعار عن بعد ونظم المعلومات الجغرافية، استعمال الفريق بصور الأقمار الصناعية لرصد ملوثات رئيسية مثل ثاني أكسيد الكبريت (SO₂)، وأكسيد النيتروجين (NO_x)، والجسيمات العالقة (PM₁₀) ، وتمت معالجة البيانات عبر برمجيات GIS لإنتاج خرائط مخاطر تلوث الهواء. هذه الخرائط مكنت السلطات المحلية من تحديد المناطق ذات الخطورة الأعلى-. وخاصة المناطق القريبة من محطات الطاقة ومصانع الفولاذ -كما ساعدت في تقييم كفاءة التدخلات التنظيمية على مدار الزمن.

وفي المملكة العربية السعودية، أثبتت تكامل نظم المعلومات الجغرافية، وتقنيات الاستشعار عن بعد، والأدوات الحيوإحصائية فعاليتها الكبيرة في تقييم وتصور ديناميكيات تلوث الهواء. تساعد هذه الأدوات الباحثين على تجاوز القيود التي تفرضها محطات الرصد الأرضية الثابتة، والتي غالباً ما تكون موزعة بشكل متباعد، ومن أبرز الأمثلة على هذا التكامل الدراسة مابلي:

- أجرت سلمان وأخرون (Salman et al., 2016) دراسة ميدانية في جنوب شرق الرياض، قامت من خلالها بتحليل مصادر التلوث وتأثيرها على السكان باستخدام نهج مختلط ضم استبيانات ميدانية (405 استبياناً)، وصور حرارية من Landsat 8، إلى جانب تحليل جغرافي باستخدام خرائط التوزيع المكاني عبر تقنية "الكريجینغ العادي" (Ordinary Kriging) ضمن برنامج ArcGIS. استهدفت الدراسة تحديد المناطق الأكثر تلوثاً وربطها بأنشطة صناعية، مثل مصنع اليمامة للأسمدة، ومحطة الطاقة في حي الفاروق. أظهرت النتائج أن أعلى تركيزات ($>403 \mu\text{g}/\text{m}^3$) PM₁₀ سُجلت في شمال وغرب منطقة الدراسة، مما تسبّب في مشكلات صحية للسكان القريبين.

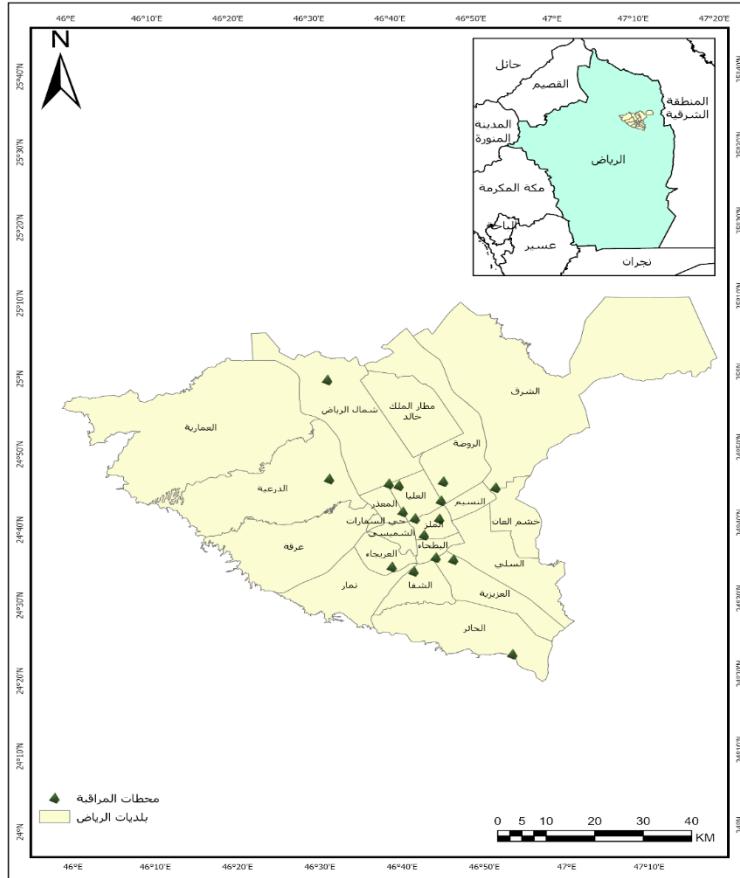


- واستخدمت دراسة متير وأخرون (2016) Munir et al. ، نهجاً اعتمد بالكامل على تقنيات الاستشعار عن بعد دون تدخل مباشر للبيانات الأرضية في معظم المواقع. حيث إنتمى على بيانات العمق البصري للهباء الجوى (AOD) Aerosol Optical Depth من القمر الصناعي MODIS لتقدير تركيزات PM_{2.5} في 20 مدينة سعودية خلال الفترة بين 2001 و2012. وقامت الدراسة بتطبيقات نماذج انحدار تربط (AOD) بتركيزات PM_{2.5} ، مع التحليل الزمانى والمكاني للتغيرات. أظهرت النتائج أن الدمام سجل أعلى التركيزات، بينما كانت تبوك الأدنى، مع وجود ميل سلبي عام من الجنوب نحو الشمال. على المستوى الزمني، لوحظت زيادات في معظم المدن باستثناء الطائف والمدينة المنورة. وأجرت الدراسة مقارنة مباشرة بين بيانات الأقمار الصناعية والرصد الأرضي في مكة المكرمة فقط، حيث أظهرت الأقمار الصناعية تركيزات أقل من الرصد الأرضي بحوالي 2.5 مرة، مما يعكس التحديات في استخدام AOD في البيئات الجافة كالسعودية.

- وتناول الزهراني (2022) دراسة التوزيع المكاني للجسيمات الدقيقة في مدينة الرياض (2016-2017)، ركزت هذه الدراسة على تحليل التوزيع المكاني لتركيز الجسيمات العالقة الدقيقة (PM_{2.5} وPM₁₀) في مدينة الرياض خلال الفترة ما بين 2016 و2017، مع تقييم علاقتها بالعوامل المناخية والتضاريس والغطاء النباتي. استخدمت الدراسة بيانات محطات جودة الهواء التابعة للهيئة الملكية، إلى جانب صور فضائية من القمر الصناعي-8 Landsat، واعتمدت تقنيات نظم المعلومات الجغرافية في التحليل. تم استخدام مؤشر الغطاء النباتي NDVI لقياس الكثافة النباتية، ونموذج الارتفاعات الرقمية (DEM) لفهم التضاريس، وطريقة مقلوب المسافة الموزونة (Inverse Distance Weighted-IDW) لرسم خرائط التركيز المكاني. وخلاصت الدراسة بتحديد ثلاثة مناطق رئيسية ذات تركيز مرتفع وهي جنوب شرق الرياض، شرقها، وشمالها، وعزت هذه التركيزات إلى عوامل مثل: وجود مصنع أسمنت الياما، انخفاض الغطاء النباتي، وتأثير العواصف الرملية. وأوضحت أن الرياح كانت العامل المناخي الأكثر تأثيراً في توزيع الجسيمات، وسجلت أكثر من 13,000 حالة تجاوز للحدود المسموحة، معظمها في فصل الربيع نتيجة نشاط العواصف الرملية المرتفع والتقلبات الجوية.

حدود الدراسة:

تند مدينة الرياض فلكياً بين دائريتي عرض 00°00'19'' إلى 00°45'27'' شمالاً، وخطي طول 00°42'' إلى 00°17'' شرقاً، وتقع جغرافياً في وسط المملكة العربية السعودية وشبه الجزيرة العربية، ويحدها من ناحية الشمال محافظات رماح، وحريلاء، والرياض، والدرعية، ومن ناحية الجنوب محافظة الرياض، ومن الشرق محافظة الرياض، ومن الغرب محافظة حريملاء، ومن الجنوب الغربي محافظة ضرما شكل (1)، وترتفع حوالي 600 متر فوق منسوب سطح البحر، وتبلغ مساحتها 5993,1 كم²، وتعد أكبر مدن المملكة وعاصمتها السياسية، كما أنها العاصمة الإدارية لمنطقة الرياض، بسكنها ما يزيد عن خمس سكان المملكة (9,6 مليون نسمة)، تحتل مدينة الرياض حالياً المرتبة (٤٨) بين مدن العالم من حيث حجم السكان وكانت في المرتبة (69) لعام 2013م، ومن المتوقع أن يصل حجم السكان إلى 9,5 مليون نسمة بحلول عام 2050، وبلغت كثافتها السكانية 2010,5 نسمة / كم²، ويبلغ نموها السكاني 4% خلال الفترة من 2009 وحتى 2016م، ويُعد بذلك من المعدلات المرتفعة بالمقارنة مع مدن العالم.



شكل (1) التقسيم الادارى ومحطات رصد ومراقبة جودة الهواء بمدينة الرياض
المصدر: (الهيئة الملكية لمدينة الرياض، 2023).

وتقسام مدينة الرياض إدارياً إلى 21 بلدية، تقسم كل بلدية إلى أحياء، بلغت جملتها 212 حي وتضم المدينة أكثر من 8318 منشأة صناعية بأنشطتها المختلفة، ومدينتين صناعيتين وهما المدينة الصناعية والمصفاة (مصفاة نقط أرامكو السعودية للمشتقات النفطية بألواءها المختلفة)، (المملكة العربية السعودية لتطوير مدينة الرياض، 2017؛ الهيئة الملكية لمدينة الرياض، 2023)، ويشهد جنوب المدينة حركة مرور كثيفة للسيارات طوال اليوم لدعم الأنشطة الصناعية بها حيث تستحوذ على ما نسبته 99,7% من إجمالي المنشآت الصناعية بالمدينة.

- منهاج الدراسة

يتم تبنيّ عدة نهج بحثية متراطبة بهدف التنبؤ بالتوزيع المكاني - الزماني لمخاطر تلوث الجسيمات الدقيقة في مدينة الرياض. في المقام الأول، اتبعت الدراسة نهجاً بحثياً كهذا PM₁₀ (Quantitative Research Approach)، بالاعتماد على بيانات رقمية من محطات الرصد الأرضية، والمتغيرات المناخية، وصور الاستشعار عن بعد، ومجموعات البيانات المكانية. ويمكن هذا النهج من إجراء قياسات موضوعية وتحليل إحصائي لتركيز PM₁₀ والعوامل المؤثرة عليهما (Creswell & Creswell, 2018)، وللتكامل مع هذا التوجّه، يتم تطبيق أيضاً منهج تحليلي مكاني (Spatial Analytical Approach)، يستند إلى علم النهج الجغرافي،



ويهدف إلى فهم الأنماط وال العلاقات المكانية للظواهر عبر المساحات الجغرافية (Goodchild & Janelle, 2010). وذلك من خلال استخدام نظم المعلومات الجغرافية وطريقة الاستيفاء المكاني باستخدام أسلوب كريجنج، حيث يتم تحويل بيانات جودة الهواء المعتمدة على نقاط الرصد إلى طبقات سطحية مستمرة، وبالتالي إنتاج خرائط موسمية للمخاطر تبرز بؤر التلوث في مختلف أنحاء مدينة الرياض.

أساليب التحليل والمعالجة:

- تحليل كريجنج (kriging)

تمت الاستفادة من البيانات المنشقة في تنفيذ التحليل المكاني بهدف نمذجة التوزيع الجغرافي لتركيز PM_{10} عبر مدينة الرياض. ولتحقيق ذلك، تم استخدام طريقة كريجنج (Kriging)، إحدى تقنيات الاستيفاء الجيوإحصائي المتقدمة، عبر برنامج ArcGIS Pro 3.4 ، لإنشاء خرائط مكانية مستمرة لتركيز PM_{10} تغطي كامل المدينة على المستوى الموسمي، وبدقة مكانية تصل إلى 30×30 متراً لكل بكسل. وتعُد تقنية كريجنج مناسبة على وجه الخصوص لمجالات علوم البيئة، نظراً لقدرتها على استغلال خاصية الارتباط الذاتي المكاني (Spatial Autocorrelation)، حيث تفترض أن القيم المقاومة في الواقع الجغرافي المجاورة تكون متشابهة إلى حد كبير. وبما أن بيانات جودة الهواء غالباً ما تجمع من عدد محدود من محطات المراقبة، فإن استخدام كريجنج يتيح توليد سطوح مكانية مستمرة تقدر القيم في الواقع غير المأهولة منها عينات، اعتماداً على القيم المتوفرة في المحطات المجاورة. ومن هذا المنطلق، فإن اختيار هذه الطريقة كان مبرراً علمياً لتمثل التوزيع المكاني لتركيز PM_{10} بدقة وموثوقية، مدعوماً بعدد من الدراسات الحديثة التي قارنت هذه الطريقة بطرق أخرى منها: مقلوب المسافة الموزونة (IDW) وأقرب جار (Nearest Neighbor) حيث خلصت دراسة (Ehrampoush et al., 2017) Kriging على IDW في تمثيل التوزيع المكاني لتركيز PM_{10} في مدينة يزد من خلال مؤشرات الدقة الإحصائية، مما يدل على دقتها في إعادة بناء السطح المكاني للملوثات في البيئات الحضرية. كما أوضحت دراسة (Halimi et al., 2016) في مدينة طهران أن Kriging لا يقتصر على إنتاج القيم المتوقعة فحسب، بل يوفر أيضاً خرائط عدم اليقين (uncertainty) المرتبطة بالتقديرات، وهو عنصر حيوي في تقييم المخاطر البيئية واتخاذ القرار المبني على درجة الثقة في التنبؤات. وفي تايلاند، أثبتت دراسة (Vorapracha et al., 2015) أن Kriging يُعد من أكثر أساليب الاستيفاء دقة في حال محدودية محطات المراقبة، خصوصاً عند اختيار نموذج مخطط شبه متغير (Semivariogram Model) مناسب. من جهة أخرى، أثبتت دراسة (Cho & Jeong, 2009) أن Kriging في مدينة سيول يوفر نتائج مكانية أكثر واقعية مقارنةً بطرق الاستيفاء التقليدية، خاصة في التقديرات الموسمية. وبناءً على ما سبق، فإن استخدام Kriging في هذه الدراسة لتقدير التركيزات الفصلية للملوث PM_{10} بمدينة الرياض يُعد منهجاً معتمداً علمياً يعزز من دقة التمثيل المكاني، ويُسهم في تحسين مخرجات النماذج التنبؤية وتحليل المخاطر البيئية.

وبناءً عليه، تتيح البيانات المقدّرة باستخدام كريجنج فرصاً إضافية لتعزيز النمذجة، حيث يمكن استخدامها كمدخلات أو أهداف في نماذج التعلم الآلي (Machine Learning)، خاصة تلك التي تدمج عوامل بيئية متعددة: درجات الحرارة، وسرعة الرياح، والرطوبة النسبية. وقد أظهرت الدراسات أن هذا النهج الهجين يُنتج نماذج أكثر قوة وواقعية، ويمكنه التقاط التفاعلات المعقّدة التي تؤثر على مستويات PM_{10} بدقة أعلى، مما يسهم في تحسين مخرجات خرائط تقييم المخاطر البيئية (Shogrkhodaei et al., 2021). وفي هذا الإطار، تم استخدام أداة Geostatistical Wizard في بيئة برنامج ArcGIS Pro 3.4 لتطبيق تقنيات الاستيفاء المكاني Kriging، التي تأخذ بعين الاعتبار كل من البعد المكاني والمتغيرات المشتركة لتحسين دقة التقديرات. وفي السياق، يتم اختيار أحد أنواع كريجنج وهو كريجنج الاعتيادي (OK - Ordinary Kriging)، حيث يُعد من أكثر طرق الاستيفاء الجيوإحصائي شيوعاً، إذ يُوفر أفضل مقدار خططي غير متخيّر للبيانات الموزعة مكانيّاً، ويُستخدم عندما لا يلاحظ اتجاه واضح في البيانات، وتحسب القيمة غير المعروفة (Z^*) في الموقع x_0 من خلال تركيبة خطية موزونة للقيم المرصودة المحيطة (x_i)، كما يلي (Oliver and Webster, 1990).



$$Z^*(x_0) = \sum \lambda_i Z(x_i), \text{ where } \sum \lambda_i = 1$$

يتم اشتقاق الأوزان λ_i من خلال حل نظام من المعادلات الخطية المبنية على نموذج مخطط شبه متغير (Semivariogram Model)، والذي يعبر عن الارتباط المكاني بين عينات النقاط. ويُعرف المخطط شبه المتغير ($\gamma(h)$) بالمعادلة:

$$\gamma(h) = (1 / 2N(h)) \sum [Z(x_i) - Z(x_i + h)]^2$$

حيث:

$\gamma(h)$ قيمة المخطط شبه المتغير عند مسافة تأخير h (Lag Distance)، وتمثل مقياس التباين بين النقاط.

$N(h)$ عدد أزواج البيانات الواقعة عند تلك المسافة h

$Z(x_i)$ القيمة المرصودة عند الموقع x_i

$Z(x_i + h)$ القيمة المرصودة عند الموقع الذي يبعد مسافة h عن x_i

ويهدف كريجينج الاعتيادي إلى تقليل تباين التقدير (Estimation Variance) مع ضمان عدم التحيز، وذلك بافتراض أن متوسط المتغير ثابت لكن غير معروف. وتُعد هذه الطريقة قوية على وجه الخصوص لأنها لا تقتصر على استيفاء القيم غير المعروفة فحسب، بل توفر أيضاً مقياساً لعدم اليقين في التقدير يُعرف بـ تباين كريجينج (Kriging Variance) ، وبحسب (Webster & Oliver, 2007) ، فإن النمذجة الدقيقة للمخطط شبه المتغير أمر بالغ الأهمية للحصول على تنبؤات موثوقة، إذ يمكن أن تؤدي تغييرات طفيفة في معابره إلى تأثيرات كبيرة على نتائج كريجينج. كما تُعد تقنية المخطط شبه المتغير أساساً محوريًا في تطبيقات الاستيفاء الجيوإحصائي باستخدام كريجينج، إذ تُستخدم لتركيب نموذج المخطط شبه المتغير النظري (النموذج الكروي أو الأسدي أو الغاوسي) والذي يستخدم لاحقاً في تقديرات كريجينج، وفي تحديد طبيعة الارتباط الذاتي المكاني (spatial autocorrelation) بين النقاط الجغرافية التي تم قياسها. ويمثل المخطط دالة إحصائية تصف كيف يتغير تباين الفرق بين القيم المرصودة مع ازدياد مسافة الفصل (lag distance) بين النقاط. وعادة ما تزداد قيمة المخطط شبه المتغير مع ازدياد المسافة، حتى تصل إلى قيمة العتبة (sill)، التي تمثل نقطة التشبع بعدها يتلاشى الارتباط المكاني، ويُعتبر المخطط حينها قد استقر عند نطاق (range) معين يعبر عن المسافة القصوى للترابط المكاني بين النقاط (Liao et al., 2006).

ويتم استخدام كل من الجذر التربيعي لمتوسط مربع الخطأ (Root Mean Square Error - RMSE)، والنسبة المئوية للجذر التربيعي لمتوسط مربع الخطأ (%)RMSE كمقياسين رئيسيين للتحقق من دقة وموثوقية نتائج الاستيفاء المكاني بطريقة كريجينج الاعتيادي، حيث يُعد RMSE مقياساً شائعاً لتقدير الفرق بين القيم المتوقعة من النموذج والقيم الفعلية المرصودة، ويُحسب باستخدام المعادلة:

$$RMSE = \sqrt{(1/\eta \sum (E_i - A_i)^2)}$$

حيث E_i : يمثل القيمة المقدرة في الموقع (i) أى تم التنبؤ بها بواسطة طريقة الاستيفاء كريجينج. (A_i) يمثل القيمة الفعلية المرصودة في الموقع (i) ، (η) هو العدد الإجمالي للبيانات المرصودة أو نقاط البيانات.



وعلى الرغم من أن RMSE يوفر مؤشراً مباشراً لحجم الخطأ، إلا أنه حساس للقيم الفائقة (outliers)، وقد يؤدي إلى تحريف النتائج. لذلك، يتم تطبيق RMSE للحصول على %RMSE، وهو مقياس نسبي أكثر توازناً يعبر عن الخطأ كنسبة مئوية من متوسط القيم المرصودة، ويحسب كما يلي:

$$\text{RMSE} = (\text{RMSE} / \mu) \times 100\%$$

حيث (μ) يمثل متوسط القيم المرصودة.

وفقاً لما ذكره Hengl et al. (2004)، فإن القيم المقبولة لمؤشر RMSE % في تطبيقات الاستيفاء المكاني تتراوح غالباً بين 20% و40%， وتشير إلى دقة جيدة في التقدير. بينما تُعد القيم التي تتجاوز 70% مؤشراً على ضعف النموذج وجود مشكلات في البنية المكانية أو طريقة التقدير المستخدمة (Hengl et al., 2004).

إلى جانب مؤشرات الخطأ RMSE و%RMSE، سُيستخدم تحليل الانحدار الخطي البسيط (Linear Regression) بين القيم المرصودة والمتوقعة من نموذج Kriging لتقييم دقة الاستيفاء. حيث يهدف هذا التحليل إلى تحديد مدى قوة العلاقة بين البيانات المُقابلة فعلياً والقيم الناتجة عن التنبؤ المكاني. وتعبر معادلة خط الانحدار عن العلاقة التالية:

$$Y = a + bX$$

حيث:

$$Y \text{ تمثل القيم المرصودة}$$

$$X \text{ القيم المتوقعة}$$

$$a \text{ الجزء المقطوع (intercept) من المحور } Y$$

$$b \text{ معامل الميل (slope)}$$

إذا كانت قيمة $b \approx 1$ و $a \approx 0$ ، فهذا يشير إلى تطابق جيد بين البيانات المتوقعة والمرصودة. كما يستخدم مخطط الانتشار (Scatter Plot) للتوضيح هذا التطابق بصرياً، حيث يُمثل كل زوج من القيم المرصودة والمترقبة نقطة. كلما اقتربت النقاط من الخط القطري، دل ذلك على ارتفاع جودة النموذج. بالإضافة إلى ذلك، يتم استخدام كل من معامل ارتباط بيرسون (r) ومعامل التحديد (R^2) ضمن أدوات التحقق الإحصائي من جودة نموذج كريجنج، لقياس درجة الارتباط بين القيم المرصودة والمترقبة. حيث يُعبر معامل الارتباط r عن قوة العلاقة الخطية بين المتغيرين، بينما يُمثل R^2 نسبة التباين في البيانات المرصودة التي يمكن تفسيرها بواسطة النموذج. ويُحسب معامل الارتباط بيرسون بالصيغة:

$$r = \left(n \times \sum XY - \sum X \times \sum Y \right) \div \sqrt{\left[\left(n \times \sum X^2 - (\sum X)^2 \right) \times \left(n \times \sum Y^2 - (\sum Y)^2 \right) \right]}$$

حيث:

r معامل الارتباط، n عدد القيم أو الأزواج، $\sum X$ مجموع قيم المتغير X ، $\sum Y$ مجموع قيم المتغير Y ، $\sum XY$ مجموع حاصل ضرب كل زوج ($X_i \times Y_i$) ، $\sum X^2$ مجموع مربعات قيم X ، $\sum Y^2$ مجموع مربعات قيم Y ، $\sqrt{\cdot}$ الجذر التربيعي.



ويحسب معامل التحديد R^2 وفقاً للمعادلة التالية:

$$R^2 = 1 - \left(\frac{SS_{\text{res}}}{SS_{\text{tot}}} \right)$$

حيث:

$$SS_{\text{res}} = \sum (y_i - \hat{y}_i)^2$$

$$SS_{\text{tot}} = \sum (y_i - \bar{y})^2$$

وتشير قيم R^2 القريبة من 1 إلى جودة تنبؤية عالية للنموذج، في حين تشير القيم المنخفضة إلى ضعف في تفسير التباين في القيم المرصودة. وقد أظهرت عدة دراسات تطبيقاً فعالاً لهذا الأسلوب، حيث استخدم في دراسة (Xia et al. 2020) تحليل الانحدار لتصحيح نموذج الاستيفاء المكاني كريجنج في الصين وقياس أداء النموذج من خلال معامل التحديد R^2 الذي تجاوز 0.9 في أكثر من 95% من موقع الرصد (Xia et al., 2020)، كما أكدت دراسة أخرى أهمية استخدام الانحدار الخطي كوسيلة دعم لتحسين خرائط تركز PM_{10} عبر النماذج الجغرافية (Karimi & Shokrinezhad, 2021).

يتبيّن مما سبق، أن تحويل بيانات محطات مراقبة الهواء المنفصلة إلى أسطح مكانية مستمرة، تُمكّن المرحلة بشكل فعال التحدّيات الناتجة عن التوزيع غير المتكافئ لمحطات الرصد في المناطق الحضرية الكبّرى. حيث سلطت دراسات سابقة حول تلوّث الهواء الضوء على الحاجة إلى أنظمة تنبؤية ديناميكية وشاملة مكانياً نظراً لتفيد انتشار الملوثات في البيئات الحضرية (Ghaemi, Alimohammadi, & Farnaghi, 2018)، وبالتالي، يشكّل الاستيفاء المكاني خطوة أساسية تمكن من بناء نماذج تقييم المخاطر المكانية المعتمدة على تقنيات التعلم الآلي.

النتائج:

أولاً: التوزيع المكاني - الزمانى لتركيز الجسيمات العالقة الدقيقة PM_{10} :

- ظهر نتائج خرائط الاشتغال المكاني بطريقة كريجنج الاعتيادي Ordinary Kriging أن مدى تركيز الجسيمات العالقة الدقيقة PM_{10} يتراوح ما بين 123.14 ميكروجرام/م³ في فصل الخريف إلى 174.94 ميكروجرام/م³ في فصل الشتاء، بمتوسط يبلغ 140.64 ميكروجرام/م³ وذلك خلال الفترة الممتدة من عام 2017 – 2021، مما يتجاوز بشكل كبير الحد السنوي الموصى به من قبل منظمة الصحة العالمية World Health Organization (WHO) والبالغ 20 ميكروجرام/م³، مع التركيز المثالي المستهدف عند 15 ميكروجرام/م³ لحماية الصحة العامة على المدى الطويل، وفقاً للتوجيهات التي تراعي الظروف البيئية الخاصة بدول مجلس التعاون الخليجي (GCC) (Gulf Cooperation Council) المتاثرة بالمناخ الجاف والغبار الصحراوي (WHO, 2021)، لذلك حددت وزارة البيئة والمياه والزراعة في المملكة العربية السعودية Ministry of Environment, Water, and Agriculture (MEWA) حد أقصى يجب عدم تجاوزه، وهو الحد المعتمد أيضاً في دولة قطر، بينما وضعت مملكة البحرين حدّاً يبلغ 80 ميكروجرام/م³ (MEWA, 2020). وما يثير القلق خاصةً تركيز PM_{10} التي تتجاوز 209.02 ميكروجرام/م³ في فصل الربيع، حيث تتحلّى الحدود الموصى بها عالمياً بأكثر من عشر مرات، والحد المحلي بأكثر من أربع مرات، مما يعكس خطورة مستويات التلوّث في مدينة الرياض.

- أما على الصعيد الفصلي، فيُعدّ فصل الربيع الأعلى تركيزاً للجسيمات العالقة الدقيقة (PM_{10})، حيث يمثل 31.1% من إجمالي التركيز لهذه الجسيمات في الفترة من 2017 إلى 2021، بمدى تركيز يتراوح بين 140.85 و 209.02 ميكروجرام/م³. وفقاً لبيانات التركيز،



تظهر ثلاثة مواقع في مدينة الرياض كأعلى مناطق تركزاً للجسيمات العالقة الدقيقة في كل فصول السنة، وفيما يلى التحليل المكانى لتوزيع الملوثات فى فصل الربيع الأعلى تركزاً فى جسيمات PM10 وذلك على النحو التالى، شكل (3):

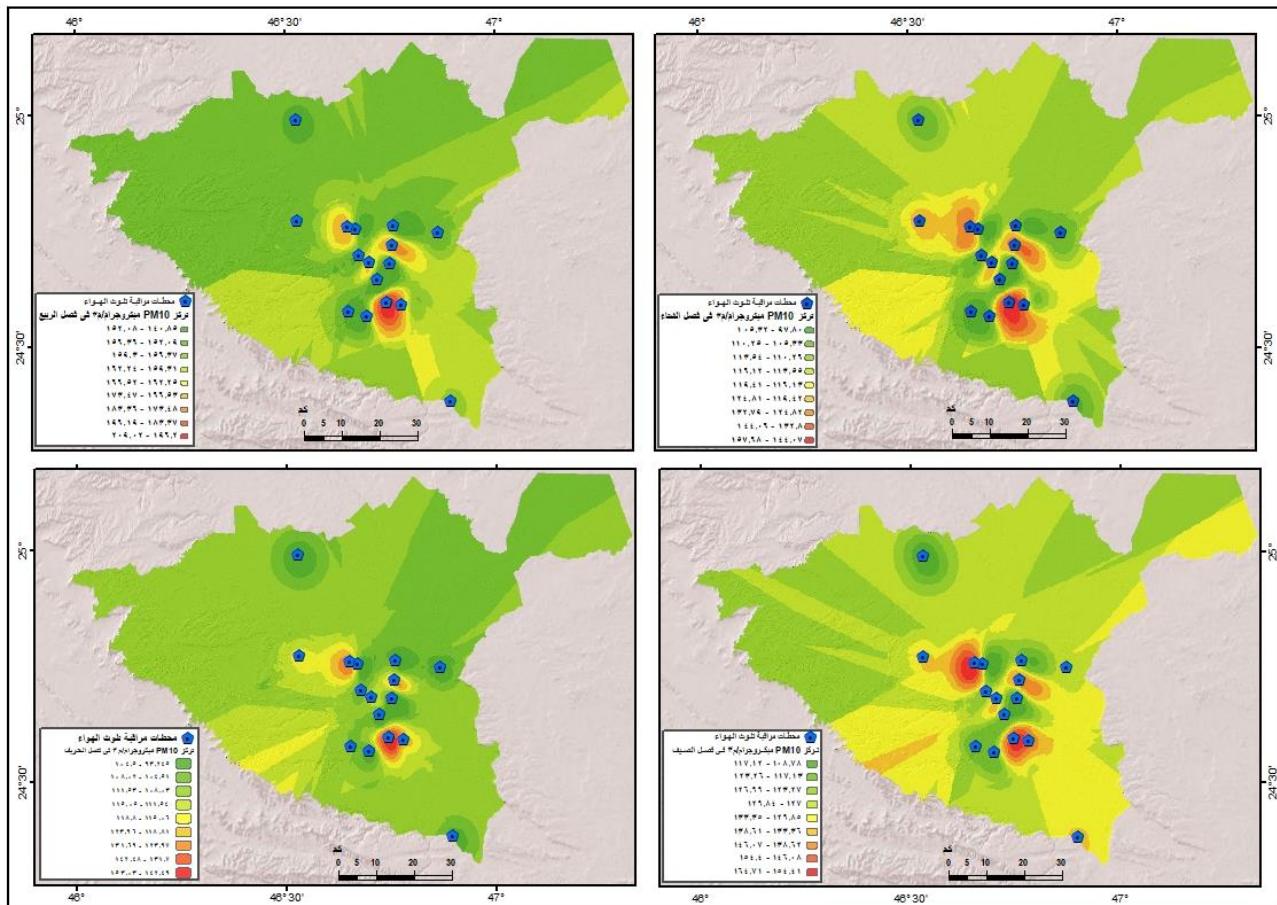
- جنوب شرق منطقة التطوير الحضري لمدينة الرياض، يشغل تركزاً الجسيمات العالقة مساحة تقدر بـ 77.4 كم² (تشكل 11.3% من إجمالي مساحة مدينة الرياض)، بالإضافة إلى مساحة 28.64 كم²، بما يمثل 16.9% من مساحة أحيا (الفيصلية، اليامامة، عتيقة، منفورة الجديدة، الخالدية، غيرا، الشفا، الدار البيضاء، المناخ، المنصورة (خنشلية)، المصانع، بدر، والمنصورية)، مع تركزاً يتراوح ما بين 166.53 و209.02 ميكروجرام/م³، وترجع هذه المستويات المرتفعة إلى عدة عوامل، منها وجود مصنع إسمنت اليامامة والمدينة الصناعية الأولى كأكبر مصادر لإنباثات PM10 ، حيث يُنتج مصنع إسمنت، على وجه الخصوص، مواد جسيمية كبيرة بسبب عملياته في احتراق الوقود، وحرق الكلنكر، ونقل المواد الخام، علاوة على الصناعات الكيميائية ومواد البناء في حي المناخ، إلى جانب انتشار صناعات مواد البناء في حي العزيزية والمصانع، وأعمال البناء الخاصة بمترو الرياض، كما تسهم إنباثات حركة المركبات الكثيفة التي تثير الغبار على الطرق والصناعات الصغيرة أيضاً في مستويات PM10 ولكنها بقدر أقل مقارنة بالمصادر الصناعية الأولية. يضاف إلى ذلك قلة الغطاء النباتي، حيث يتمركز في وادي حنيفة، وتؤدي الرياح القادمة من الجنوب والجنوب الشرقي إلى تفاقم انتشار PM10 نحو المناطق المكتظة بالسكان حيث تحمل الرياح الملوثات من المراكز الصناعية إلى المناطق السكنية القريبة مما يسهم في نقل وتنبيط الملوثات جنوب شرق الرياض (Salman et al., 2016; الزهراني، 2022).

- بينما يغطي تركزاً الجسيمات العالقة PM 10 في شرق منطقة التطوير الحضري لمدينة الرياض، مساحة تقدر بـ 33.7 كم²، ما يمثل 0.6% من إجمالي مساحة مدينة الرياض، و23 كم²، بنسبة 22.9% من إجمالي مساحة أحيا (السلام، النموذجية، المربع، الفيحاء، الروابي، الروضة، الريان، المنار، السليمانية، الملك عبدالعزيز، الملك عبدالله، والعلبي)، مع مدى تركزاً يتراوح ما بين 166.53 إلى 183.36 إلى 183.36 ميكروجرام/م³. ويرجع ذلك إلى عدة عوامل، منها كثافة حركة المركبات التي تثير الغبار على الطرق (طريق مكة المكرمة والطريق الدائري الشرقي)، وندرة الغطاء النباتي، إضافةً إلى ذلك، تلعب سرعة واتجاه الرياح الشمالية الشرقية دوراً في نقل وتركزاً الجسيمات العالقة الدقيقة (PM10) القادمة من العروق والكتبان الرملية ومنها عرق بنيان. كما يسهم الارتفاع التدريجي لسطح الأرض شرقى المدينة في تركزاً الجسيمات، حيث يتراوح متوسط الارتفاع بين 607 و638 متراً عن مستوى سطح البحر (الزهراني، 2022).

- وتمثل المنطقة الثالثة في شمالى منطقة التطوير الحضري لمدينة الرياض حيث يشغل تركزاً الجسيمات العالقة PM 10 مساحة تقدر بـ 27 كم² (تشكل نسبة 0,5% من إجمالي مساحة مدينة الرياض، و27,02 كم²، بنسبة بلغت 34,8% من إجمالي مساحة أحيا (العقيق، المروج، الغدير، الملك فهد، الربيع، الصحافة، النخيل، جامعة الملك سعود، حطين، المحمدية). حيث قدّر مدى تركزاً الجسيمات العالقة الدقيقة (PM10) بـ 166.53 - 173.47 ميكروجرام/م³، ويعزى ذلك إلى الكثافة السكانية والعمرانية والأنشطة التجارية (مشروع مترو الرياض، ومركز الملك عبدالله المالي)، علاوة على كثافة حركة مرور المركبات خاصةً (الطريق الدائري الشمالي) التي تثير الغبار على الطرق. بينما يتراوح تركزاً الجسيمات الدقيقة العالقة (PM10) في باقى أنحاء مدينة الرياض (منطقة التطوير الحضري وحدود حماية التنمية) ما بين 140.85 و166.52 ميكروجرام/م³. حيث تتأثر بشدة بكل من العوامل الطبيعية (العواصف الترابية وضعف التربة وتقكها، مما يسهل على الرياح حمل هذه الجزيئات. ويسهم في ذلك أيضاً سرعة الرياح واتجاهها الشمالي الشرقي مما يؤدي إلى نقل وتنبيط الجسيمات العالقة في المدينة. بالإضافة إلى ذلك، يسهم الارتفاع التدريجي للأرض، باتجاه الشمال والشمال الغربي والغرب، والذي يتراوح بين 629 و939 متراً فوق مستوى سطح البحر، في زيادة استقرار هذه الجسيمات (Alharbi et al., 2015; الزهراني، 2022). بالإضافة إلى الأنشطة البشرية (كثافة حركة المرور اليومية والانبعاثات الصناعية وأعمال إنشاء مترو الرياض). في المقابل، تمثل المناطق الغربية من مدينة



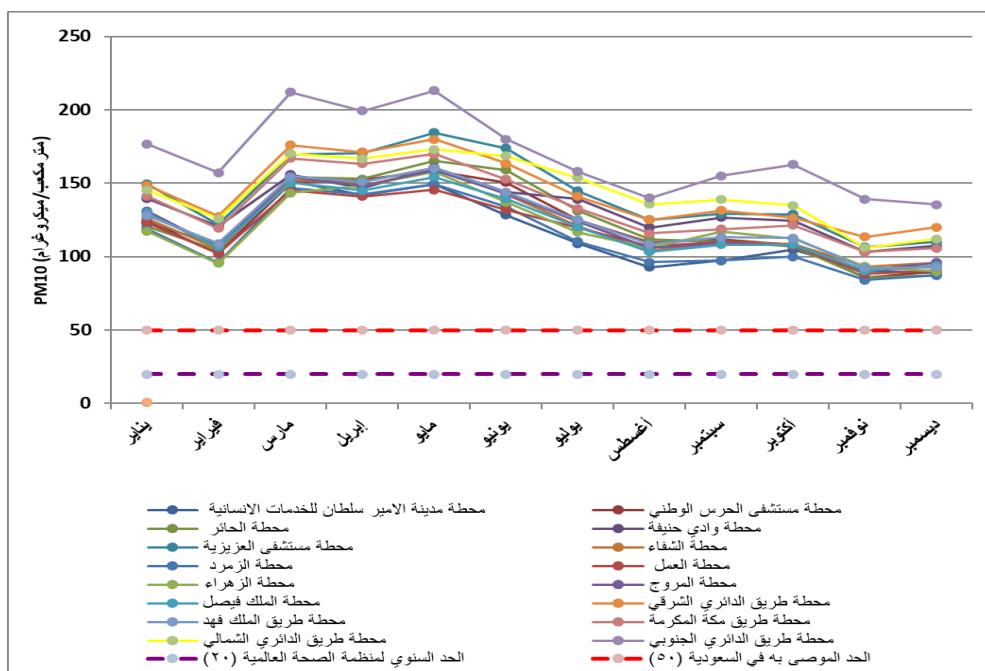
الرياض، ذات المناطق المفتوحة والنشاط البشري الأقل والبعيدة عن المناطق الحضرية والتركيز الصناعي إلى تسجيل مستويات أقل من جسيمات PM10.





الحضري لمدينة الرياض، بسبب الظروف الجوية الأكثر استقراراً وإنخفاض درجات الحرارة وارتفاع نسبه الرطوبة وزيادة كمية هطول الأمطار، مما يساعد على منع إعادة تعليق الغبار وترسيب الجسيمات، كما تعدد الانبعاثات الصناعية وحركة مرور المركبات هي المساهمين الرئيسيين في مستويات PM10، حيث يكون الغبار الطبيعي أقل انتشاراً. وقد يؤدي فصل الشتاء أحياناً إلى انقلاب درجات الحرارة، حيث يحبس الهواء البارد الملوث بالقرب من سطح الأرض. يمكن أن يؤدي ذلك إلى زيادة مستويات PM10 بشكل مؤقت، خاصة في المناطق الحضرية المكتظة بالسكان، على الرغم من أن ترتكز PM10 في فصل الشتاء تظل أقل مما كانت عليه في فصلي الربيع والصيف (Alharbi et al., 2015; Altuwayjiri et al., 2022).

- خلال فصل الخريف يكون ترتكز PM10 بشكل عام في أدنى مستوياتها بنسبة تصل إلى 21,89% من جملة الترتكز، وتراوح مدى ترتكز جسيمات PM 10 ما بين 93,25 إلى 153,01 ميكروجرام/م³، ومبين إلى 118,81 إلى 153,03 ميكروجرام/م³ لترتكز جسيمات PM10 المرتفعة، وتتوزع أيضاً في جنوب شرق وشمال منطقة التطوير الحضري لمدينة الرياض، ويرجع ذلك إلى انخفاض وتيرة العواصف الترابية وتصبح الظروف الجوية أكثر استقراراً. وبينما تنخفض إعادة تعليق الغبار الطبيعي، وتستمر الانبعاثات الصادرة عن حركة المرور والصناعة في المساهمة في PM10 ، خاصة في المناطق الحضرية. وتشهد درجات الحرارة المنخفضة وارتفاع نسبه الرطوبة وهطول الأمطار على ترسب الجسيمات على سطح الأرض مما يقلل من مستويات PM10 مقارنة بفصلي الربيع والصيف.



الشكل (4) المتوسطات الشهرية لترتكز 10 PM في مدينة الرياض خلال الفترة الممتدة ما بين عامي 2017-2021 م

- أظهرت السلاسل الزمنية لترتكز 10 PM في مدينة الرياض خلال الفترة الممتدة ما بين عامي 2017-2021 م الشكل (4) أن جميع محطات الرصد تتجاوز الحدود التوجيهية لترتكز 10 PM طوال العام، حيث تراوحت قيمه



بين 85,9 و 212,9 ميكروجرام / م³، في حين أن الحد الموصى به في المملكة العربية السعودية 50 ميكروجرام / م³ والحد الموصى به من منظمة الصحة العالمية 20 ميكروجرام / م³، حيث سُجلت أعلى القيم في شهور فصل الربيع حيث سجل شهر مايو ومارس وإبريل 212,9 و 219,2 و 199,2 ميكروجرام / م³ لكل منها على الترتيب في محطة طريق الدائري الجنوبي، بينما كانت أدنى قيم سُجلت في فصل الشتاء شهر نوفمبر 85,9 ميكروجرام / م³، وشهر ديسمبر 87,5 ميكروجرام / م³ في محطة الحائز، ومع ذلك لا تزال هذه القيم تتجاوز الحدود الآمنة الموصى بها، مما يشير إلى تفاوت مكاني واضح في التلوث. وتعزى هذه الاختلافات إلى العوامل الموسمية مثل العاصف الرملية وقلة الأمطار، إضافة إلى العوامل البشرية مثل النشاط الصناعي وحركة المرور كما سبق ذكرها بالفصيل كما سبق.

- تبين من استخدام طريقة التحقق المتقاطع Cross validation من صحة نتائج الاستنبطانة عن استخدام طريقة كريجينج الاعتيادي (OK) لـ 16 محطة ثابتة مراقبة تلوث الهواء بالجسيمات الدقيقة العالقة PM10 للفترة الممتدة من 2017-2021م على مستوى فصول السنة، وذلك من خلال استخدام متوسط مربع جذر الخطأ Root Mean Squared Error (RMSE) والسبة المئوية لمتوسط جذر الخطأ %RMSE، بالإضافة إلى استخدام معامل الارتباط بيرسون Pearson Coefficient ومعادلة خط الإنحدار البسيط simple linear regression equation ومعامل التحديد -R (Correlation coefficient of determination square) وقياسه وتمثيله بيانياً عن طريق إنشاء مخطط التشتت أو الانشار Scatterplots، ما يلى:

. أظهر استخدام RMSE و RMSE %MSE موثوقية الاعتماد على طريقة كريجينج الاعتيادي في الاستيفاء المكاني لتقدير قيم جسيمات PM10 في الواقع التي لا تتوافر لها بيانات مرصودة وإعداد خرائط دقيقة لـ PM10 على أساس فصلي، حيث تقع %RMSE لكل فصل ضمن الحد المقبول، فقيمة %RMSE لفصل الشتاء بلغت 3,51 %، وفصل الربيع 2,79 %، وفصل الصيف 2,50 %، وفصل الخريف 15,15 % مما يؤكد دقة الاستيفاء المقبولة لكل فصل في السنة جدول (5). فوفقاً لهنجل وآخرون وشکرخادائی وآخرون (Shogrkhodaei et al., 2021; Hengl et al., 2004) تعتبر قيمة %RMSE التي تقل عن 40 % مقبولة، مما يشير إلى أن الاستيفاء يمثل بدقة البيانات المرصودة، في حين تشير القيم الأعلى من 70 % إلى عدم دقة في تقديرات النموذج.

جدول (5) تقييم دقة الاستيفاء بطريقة كريجينج الاعتيادي للجسيمات الدقيقة العالقة PM10 للفترة الممتدة من عام 2017 – 2021م

فصل السنة	متوسط مربع جذر الخطأ (RMSE)	النسبة المئوية لمتوسط جذر الخطأ %RMSE	الأداء	معامل ارتباط بيرسون (r)
الشتاء	4,067	3,51	مقبول	0,983
الربيع	3,263	2,50	مقبول	0,983
الصيف	4,463	2,79	مقبول	0,978
الخريف	5,713	5,15	مقبول	0,943

. تأكيد من تطبيق معامل الارتباط بيرسون أن العلاقة الخطية بين القيم المرصودة والمقدرة لقيم جسيمات PM10 على مستوى فصول السنة إيجابية طردية قوية، حيث وصلت قيمة المعامل في فصل الشتاء والربيع إلى (0,983)، وفي فصل الصيف والخريف بلغت (0,978 و 0,943) على التوالي جدول (5). مما يعني أنه مع زيادة القيم "المرصودة"، تميل القيم "المقدرة" أيضاً إلى الزيادة. فالقيم الأقرب إلى 1 تشير إلى علاقة خطية قوية، مما يؤكد دقة نموذج الانحدار في التقاط العلاقة بين القيم "المرصودة" و"المقدرة". وبالتالي يمكن الاعتماد على النموذج في اتباع اتجاه القيم "المرصودة". وأن أداء النموذج جيداً للتنبؤات في مجموعة هذه البيانات.

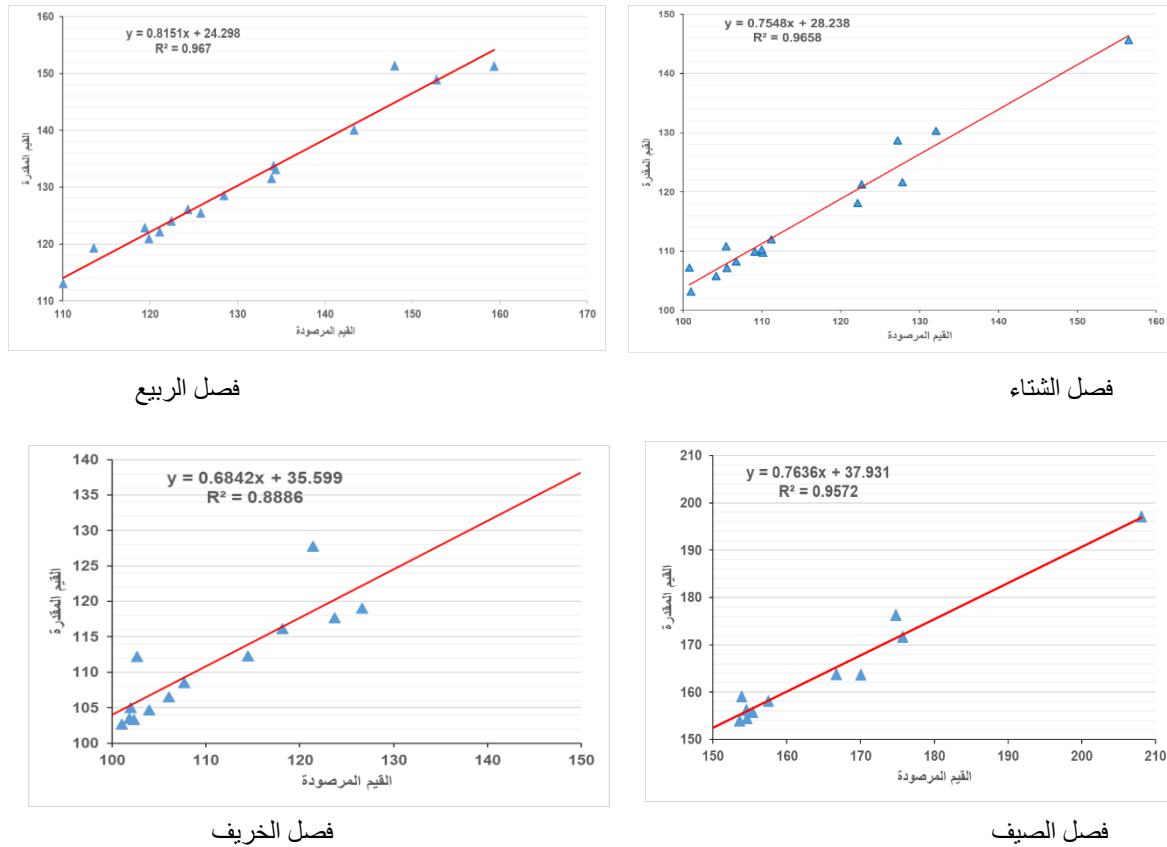


تشير قيمة معامل التحديد (R^2) البالغة (0.966، 0.957، 0.967، 0.889) في فصل الشتاء والربيع والصيف والخريف على الترتيب، أن 95.7% من التباين في القيم "المقدرة" يتم تقسيمه من خلال القيم "المرصودة"، حيث تشير قيمة معامل التحديد (القريبة من 1) إلى أن النموذج يلتقط اتجاه البيانات بشكل جيد، ويؤكد على قدرة النموذج على التقاط تباين كبير في القيم "المقدرة"، مع الحد الأدنى من خطأ التنبؤ لل نقاط القريبة من الخط مما يدل على وجود علاقة موثقة بين القيم المرصودة والمقدرة. ومن ثم فعالية النموذج في إجراء التنبؤات ضمن نطاق هذه البيانات (Harris et al., 2020; Pedregosa et al., 2011). ويتم حساب خط الانحدار لتقليل أخطاء التنبؤ، مما يوضح بشكل أساسي الاتجاه المتوسط (Field, 2013)، حيث تمثل القيمة 0.755، 0.764، 0.764، 0.815 الميل في فصول السنة، مما يشير إلى معدل التغير، أي أنه مقابل كل زيادة بمقدار وحدة واحدة في القيم المرصودة، تزيد القيم المقدرة" بنحو 0.755، 0.764، 0.815، 0.684 وحدة. (يشير المنحدر أقل من 1 إلى أن القيم "المقدرة" تنمو بمعدل أبطأ مقارنة بالقيم "المرصودة")، بينما يحدد الجزء المقطوع من المحور "Y" (28.238، 24.298، 37.931، 35.599) خط الأساس للتنبؤات عندما تساوي "القيم المرصودة" صفرًا جدول (6) (Moore et al., 2012). بالإضافة إلى ذلك، يوضح مخطط التشتت أو الانتشار مع خط الانحدار الخطي بشكل بياني العلاقة بين القيم "المرصودة" و"المقدرة"، حيث تمثل كل نقطة زوجًا من القيم "المرصودة" و"المقدرة"، مما يسمح بالتقدير السهل لتجميع البيانات وسلوك متابعة الاتجاه ويوضح انتشار هذه النقاط مدى قرب القيم "المقدرة" من اتجاه القيم "المرصودة". عندما تجتمع النقاط حول الخط المستقيم، وهذا يشير إلى وجود علاقة خطية قوية بين المتغيرات (Moore, McCabe, & Craig, 2012)، يمثل الخط الأحمر خط الانحدار الخطي الأنسب، وظهور النقاط القريبة من الخط الحد الأدنى من خطأ التنبؤ، مما يعني أن القيم "المقدرة" للنموذج دقيقة بالنسبة لهذه القيم "المرصودة". النقاط بعيدة عن الخط بها أخطاء تنبؤية أعلى، مما يشير إلى بعض التباين الذي لم يلتقطه النموذج شكل (5).



**جدول (6) معادلة خط الإنحدار البسيط للجسيمات الدقيقة العالقة PM10 المرصودة والمقدرة بطريقة كريجنج
الاعتيادي للفترة الممتدة من عام 2017 – 2021**

الخريف		الصيف		الربيع		الشتاء		فصول السنة
القيمة المقدرة (Y)	القيمة المرصودة (X)	المحطات						
99,98	97,58	149,18	147,83	113,13	110,06	108,30	106,71	مدينة الامير سلطان الإنسانية
103,52	101,82	154,06	153,63	128,58	128,42	107,17	105,55	مستشفى الحرس الوطني
102,68	101,04	158,10	157,49	133,75	134,12	105,84	104,22	الحائر
116,20	118,11	154,50	154,58	133,16	134,37	121,29	122,66	وادي حنيفة
127,78	121,42	176,32	174,81	151,41	147,95	128,69	127,19	مستشفى العزيزية
104,70	103,91	156,32	154,55	124,03	122,42	109,95	109,13	الشفا
104,57	93,79	153,92	146,15	119,31	113,59	107,22	100,79	الزمرد
105,05	101,98	149,74	143,93	122,87	119,40	110,86	105,48	العمل
108,57	107,70	151,69	149,88	120,99	119,85	103,18	101,02	الزهرة
112,21	102,65	159,13	153,87	126,12	124,31	112,02	111,17	المروج
103,31	102,28	148,57	149,86	122,17	121,09	109,69	110,15	الملك فيصل
117,65	123,74	171,79	175,70	140,09	143,31	130,32	132,10	الطريق الدائري الشرقي
106,57	106,03	155,82	155,36	125,47	125,80	110,24	109,98	طريق الملك فهد
112,35	114,47	163,77	166,73	131,58	133,90	118,11	122,16	طريق مكة المكرمة
119,04	126,65	163,68	170,01	148,95	152,73	121,66	127,83	الطريق الدائري الشمالي
140,26	152,40	197,12	208,07	151,30	159,31	145,63	156,52	الطريق الدائري الجنوبي
0,889		0.957		0.967		0.966		معامل التحديد (R^2)
35.599		37.931		24.298		28.238		الجزء Intercept (a) المقطوع من المحور Y
0.684		0.764		0.815		0.755		Slope (b) الميل



شكل (5) مخطط الانتشار وخط الانحدار البسيط الموسمي لمتوسطات ترکز PM10 خلال الفترة (2017-2021) في مدينة الرياض

خلاصة النتائج (الاستنتاجات)

وكشفت نتائج الدراسة عدد من الرؤى المهمة، يمكن إبرازها على النحو التالي:

- تبين من خلال تحليل توزيع الجسيمات الدقيقة العلاقة في الهواء PM₁₀ في مدينة الرياض بين عامي 2017 و2021 باستخدام طريقة الاشتقاق المكانى كريجينة الاعتيادى للبيانات المقاسة أن مستويات ترکز PM₁₀ على المستوى السنوى تراوحت بين بين 123.14 ميكروغرام/م³ في فصل الخريف و174.94 ميكروغرام/م³ في فصل الشتاء، بمتوسط قدره 140.64 ميكروغرام/م³، مما يتجاوز الحد السنوى الذى تحده منظمة الصحة العالمية (20 ميكروغرام/م³)، ومن الملاحظ أن ترکزات PM₁₀ خلال فصل الربيع كانت الأعلى، حيث تجاوزت 209.02 ميكروغرام/م³، وهو ما يفوق بكثير الحدود العالمية والمحلية. أما على المستوى الفصلى، فقد شهد فصل الربيع أعلى ترکز PM₁₀ حيث مثل 31.1% من إجمالي التركيز السنوى، وتراوحت القيم خلاله ما بين 140.85 و209.02 ميكروغرام/م³. ومكانتها كان ترکز PM₁₀ أعلى خلال الفصل في مناطق جنوب شرق وشمال الرياض كما هو الحال فى باقى فصول السنة، متاثرة بعوامل الانبعاثات الصناعية، وحركة المرور، وسرعة الرياح واتجاهها والعواصف الترابية. أما فى فصل الصيف، فعلى الرغم من أن كانت مستويات PM₁₀ أقل قليلاً مقارنة بفصل الربيع ولكنها ظلت مرتفعة، حيث تراوحت بين 108.78



و 164.71 ميكروغرام/م³، ونتجت عن العواصف الترابية ودرجات الحرارة العالية. بينما شهد فصل الشتاء أدنى مستويات ترکز PM₁₀ (من 97.8 إلى 157.56 ميكروغرام/م³)، ويرجع ذلك على الأرجح إلى درجات الحرارة المنخفضة والرطوبة العالية التي تساعد على تقليل إعادة تعليق الغبار. كما كان أيضاً فصل الخريف أقل نسبياً في ترکز PM₁₀، حيث تراوحت بين 93.25 و 153.01 ميكروغرام/م³. وبشكل عام، توزعت أعلى ترکزات في مناطق التطوير الحضري جنوب شرق الرياض، بما في ذلك أحياe مثل الفيصلية ومنفورة، بسبب القرب من المصادر الصناعية حيث مصانع الأسمنت والأنشطة الإنسانية. كما أظهرت المناطق الشرقية والشمالية بالمدينة أيضاً مستويات مرتفعة، تأثرت بحركة المرور والانبعاثات الصناعية، فضلاً عن الخصائص الجغرافية كارتفاع مستوى سطح الأرض، وفي المقابل المناطق الغربية من مدينة الرياض، التي تشهد نشاطاً صناعياً أقل ومساحات مفتوحة أكبر، عرضت ترکزات PM₁₀ أقل.

- استخدمت الدراسة طرق التحقق المتقاطع وتمثلت في النسبة المئوية لمتوسط جذر الخطأ RMSE% ، معامل الارتباط بيرسون ، ومعامل التحديد (R-square) للتحقق من دقة النموذج المكاني كريجينغ الاعتيادي، أظهرت النتائج أن النموذج قد تنبأ بدقة ترکزات PM₁₀، حيث كانت قيم RMSE% منخفضة (من 2.5% إلى 5.15%)، وكان معامل الارتباط بيرسون مرتفعاً (أعلى من 0.94 لجميع الفصول). وتراوحت قيم معامل التحديد R² من 0.89 إلى 0.97، مما يشير إلى قدرة قوية للنموذج في التنبؤ بمستويات PM₁₀ مع هامش خطأ ضئيل، بالإضافة إلى ذلك أظهر التحليل الانحدار الخطى البسيط علاقة خطية إيجابية بين ترکزات PM₁₀ الملاحظة والمقدرة، مع قيم انحدار تشير إلى معدل زيادة القيم المقدرة مقارنة بالقيم الملاحظة (المقاسة). وبالتالي، يمكن الاعتماد على هذا النموذج في التنبؤ بمستويات PM₁₀ عبر الفصول المختلفة والموقع داخل الرياض.

وبناءً عليه، تؤكد الدراسة على مستويات التلوث العالية لجسيمات PM₁₀ في الرياض، وخاصة في فصل الربيع، الناتجة عن الأنشطة الصناعية وحركة المرور والعواصف الترابية. وتبرز النتائج الحاجة إلى تدابير صارمة لمراقبة جودة الهواء لحماية صحة العامة.

التوصيات:

استناداً إلى نتائج الدراسة، هناك العديد من المجالات الوعادة التي يمكن أن تسهم في تعزيز فهم تلوث PM₁₀ وتأثيراته على البيئات الحضرية. هذه المجالات موضحة أدناه، وذلك على النحو التالي:

1- تكامل البيانات في الوقت الفعلي Integration of Real-Time Data : بينما استخدمت الدراسة البيانات التاريخية لتطوير النماذج، يمكن أن يُسهم دمج البيانات في الوقت الفعلي من أجهزة استشعار جودة الهواء، وأنظمة مراقبة حركة المرور، ومحطات الطقس بشكل كبير في تعزيز دقة وتوقيت التنبؤات بـ PM₁₀. سيسمح الرصد في الوقت الفعلي بتقييمات مخاطر ديناميكية وتحذيرات صحية عامة في الوقت المناسب، مما يحسن استجابة أنظمة إدارة جودة الهواء.

3- التوسيع في دراسة ملوثات أخرى: بينما ركزت الدراسة على PM₁₀ ، فإن ملوثات أخرى منها: PM_{2.5} ، وأكسيد النيتروجين (NOx) ، وأكسيد الكبريت (SOx) تعد أيضاً ذات أهمية كبيرة لجودة الهواء والصحة العامة. يمكن أن يمتد البحث المستقبلي إلى دمج نهج المندجة المكانية الزمنية لتشمل هذه الملوثات، مما يتتيح تقييمًا أكثر شمولاً لمخاطر جودة الهواء واستراتيجيات التخفيف المستهدفة بشكل أفضل لتلوث الهواء الحضري.

4- دمج العوامل الاجتماعية والسلوكية: يمكن للبحوث المستقبلية استكشاف العوامل الاجتماعية والسلوكية التي تسهم في التعرض لـ PM₁₀ والمخاطر في السكان الحضريين. على سبيل المثال، قد تختلف نتائج الصحة المتعلقة بالposure لـ PM₁₀ بين الأحياء بناءً على عوامل مثل مستويات الدخل، والوصول إلى الرعاية الصحية، والوعي العام بمخاطر تلوث الهواء. يمكن أن يعزز دمج هذه المتغيرات من دقة خرائط المخاطر ويضمن أن تكون جهود التخفيف عادلة وشاملة.

5- الدراسات الطويلة حول التأثيرات الصحية: بينما ترکز هذه الدراسة على نمذجة التوزيع المكانية الزمنية لـ PM₁₀ ، يمكن للبحوث المستقبليةربط بيانات التلوث بنتائج الصحة من خلال إجراء دراسات طويلة. يمكن أن



تبحث هذه الدراسات في التأثيرات الصحية المباشرة للتعرض لـ PM_{10} ، بما في ذلك معدلات الأمراض التنفسية والأمراض القلبية والوفاة، مما يساعد على قياس عبء الصحة العامة الناجم عن تلوث الهواء في البيئات الحضرية.

6- تطوير أنظمة دعم القرار التفاعلية: يمكن للبحوث المستقبلية التركيز على إنشاء أنظمة دعم القرار التفاعلية لمخطط المدن وصانعي السياسات. يمكن أن تدمج هذه الأنظمة بيانات جودة الهواء في الوقت الفعلي، والنماذج المعتمدة على التعلم الآلي، وخرائط المخاطر المرئية لدعم اتخاذ القرارات المستندة إلى البيانات. يمكن أن تساعد هذه الأنظمة في التخطيط لتدابير مكافحة التلوث، وتصميم المساحات الخضراء، واتخاذ قرارات التنظيم الحضري التي تقلل من التعرض للملوثات الضارة.

7- تقييم استراتيجيات التخفيف من التلوث: يمكن أيضًا أن تركز الدراسات المستقبلية على تقييم فعالية استراتيجيات التخفيف من التلوث المختلفة، بما في ذلك إدارة حركة المرور، وتنظيمات الصناعة، وتطوير البنية التحتية الخضراء. يمكن أن تركز الأبحاث على مقارنة المناطق ذات مستويات التدخل المختلفة لتقييم مدى نجاح استراتيجيات متعددة في تقليل تركزات PM_{10} وتحسين جودة الهواء في المناطق الحضرية.

8- استخدام علوم المواطن Citizen Science : من خلال دمج مبادرات علوم المواطن في مراقبة جودة الهواء، يمكن جمع بيانات قيمة وزيادة مشاركة الجمهور في قضايا جودة الهواء. يمكن للبحوث المستقبلية استكشاف استخدام أجهزة استشعار هواء منخفضة التكلفة موزعة عبر المدن لتوليد بيانات جودة الهواء المعتمدة على المشاركة الجماعية، التي يمكن دمجها مع نماذج التعلم الآلي للتنبؤات المحلية والشخصية.

وبناءً عليه، من خلال توسيع هذه المجالات البحثية، يمكن للدراسات المستقبلية تحسين النماذج التنبؤية، وتطوير استراتيجيات أكثر فعالية لإدارة جودة الهواء، وتحسين نتائج الصحة العامة في المناطق الحضرية. ستكون هذه الجهود حاسمة في مواجهة تحدي تلوث الهواء الحضري المتزايد وتأثيراته على المجتمعات في جميع أنحاء العالم.

المراجع

1. Zhang, L., Li, X., Zheng, D., Zhang, K., Ma, Q., Zhao, Y., & Ge, Y. (2021a). Merging multiple satellite-based precipitation products and gauge observations using a novel double machine learning approach. *Journal of Hydrology*, 594, 125969. <https://doi.org/10.1016/j.jhydrol.2021.125969>
2. World Health Organization. (2021b). WHO global air quality guidelines: Particulate matter ($PM_{2.5}$ and PM_{10}), ozone, nitrogen dioxide, sulfur dioxide and carbon monoxide. <https://www.who.int/publications/i/item/9789240034228>
3. Orellano, P., Kasdagli, M. I., Pérez Velasco, R., & Samoli, E. (2024). Long-Term Exposure to Particulate Matter and Mortality: An Update of the WHO Global Air Quality Guidelines Systematic Review and Meta-Analysis. *International journal of public health*, 69, 1607683. <https://doi.org/10.3389/ijph.2024.1607683>
4. Barrett J. R. (2015). "Exported" deaths and short-term PM_{10} exposure: factoring the impact of commuting into mortality estimates. *Environmental health perspectives*, 123(1), A22. <https://doi.org/10.1289/ehp.123-A22>
5. Alharbi, H. A., Rushdi, A., Bazeyad, A. Y., & Al-Mutlaq, K. (2024). Temporal variations, air quality, heavy metal concentrations, and environmental and health impacts of atmospheric $PM_{2.5}$ and PM_{10} in Riyadh City, Saudi Arabia. *Atmosphere*, 15(12), 1448. <https://doi.org/10.3390/atmos15121448>



6. Modaihsh, A. , Al-Barakah, F. , Nadeem, M. and Mahjoub, M. (2015) Spatial and Temporal Variations of the Particulate Matter in Riyadh City, Saudi Arabia. *Journal of Environmental Protection*, 6, 1293-1307. doi: 10.4236/jep.2015.611113.
7. Al-Zboon, K., Matalqah, W., & Ammary, B. (2021). Effect of cement industry on ambient air quality and potential health risk: A case study from Riyadh, Saudi Arabia. *Jordanian Journal of Engineering and Chemical Industries*, 4(1), 14–23. <https://doi.org/10.48103/jjeci422021>
8. Yasin, K. H., Yasin, M. I., Iguala, A. D., Gelete, T. B., Tulu, D., & Kebede, E. (2025). Predictive machine learning and geospatial modeling reveal PM10 hotspots and guide targeted air pollution interventions in Addis Ababa, Ethiopia. *Discover Applied Sciences*, 7(263). <https://doi.org/10.1007/s42452-025-06723-w>
9. Almaliki, A., & Khattak, A. (2024). Synergizing TabNet and SHAP for PM10 forecasting: Insights from Makkah, Saudi Arabia. *IEEE Access*, 12, 195528–195543. <https://doi.org/10.1109/ACCESS.2024.3520815>
10. Altuwayjiri, A., Pirhadi, M., Kalafy, M., Alharbi, B. H., & Sioutas, C. (2021). Impact of different sources on the oxidative potential of ambient particulate matter PM10 in Riyadh, Saudi Arabia: A focus on dust emissions. *The Science of the Total Environment*, 150590. <https://doi.org/10.1016/j.scitotenv.2021.150590>
11. Salman, A., Al-Tayib, M., Hag-Elsafi, S., & Al-Duwarij, N. (2016). Assessment of pollution sources in the southeastern of Riyadh and its impact on the population/Saudi Arabia. *Arabian Journal of Geosciences*, 9, 1–16. <https://doi.org/10.1007/s12517-016-2371-4>
12. Bian, Q., Alharbi, B. H., Shareef, M. M., Husain, T., Pasha, M., Atwood, S., & Kreidenweis, S. (2017). Sources of PM_{2.5} carbonaceous aerosol in Riyadh, Saudi Arabia. *Atmospheric Chemistry and Physics*, 18, 3969–3985. <https://doi.org/10.5194/ACP-18-3969-2018>
13. Shogrhodaei, S. Z., Razavi-Termeh, S. V., & Fathnia, A. (2021). Spatio-temporal modeling of PM2.5 risk mapping using three machine learning algorithms. *Environmental Pollution*, 289, 117859. <https://doi.org/10.1016/j.envpol.2021.117859>
14. Rojas-Rueda, D., Alsufyani, W., Herbst, C., AlBalawi, S., Alsukait, R., & Alomran, M. (2021). Ambient particulate matter burden of disease in the Kingdom of Saudi Arabia. *Environmental Research*, 111036. <https://doi.org/10.1016/j.envres.2021.111036>
15. Brook, R. D., Rajagopalan, S., Pope, C. A., et al. (2010). Particulate matter air pollution and cardiovascular disease: An update to the scientific statement from the American Heart Association. *Circulation*, 121(21), 2331–2378. <https://doi.org/10.1161/CIR.0b013e3181dbece1>
16. Pope, C. A., & Dockery, D. W. (2006). Health effects of fine particulate air pollution: Lines that connect. *Journal of the Air & Waste Management Association*, 56(6), 709–742. <https://doi.org/10.1080/10473289.2006.10464485>
17. Cressie, N., & Wikle, C. K. (2011). Statistics for spatio-temporal data. John Wiley & Sons.



18. Li, S., Dragicevic, S., & Veenendaal, B. (2021). GeoAI: Applications and emerging trends. *International Journal of Geographical Information Science*, 35(3), 365–384. <https://doi.org/10.1080/13658816.2020.1797490>
19. Rybarczyk, Y., & Zalakeviciute, R. (2018). Machine learning approaches for outdoor air quality modelling: A systematic review. *Applied Sciences*, 8(12), 2570. <https://doi.org/10.3390/app8122570>
20. Shogrhodaei, S. Z., Razavi-Termeh, S. V., & Fathnia, A. (2021). Spatio-temporal modeling of PM2.5 risk mapping using three machine learning algorithms. *Environmental Pollution*, 289, 117859. <https://doi.org/10.1016/j.envpol.2021.117859>
21. Ghaemi, Z., Alimohammadi, A., & Farnaghi, M. (2018). LaSVM-based big data learning system for dynamic prediction of air pollution in Tehran. *Environmental Monitoring and Assessment*, 190, 300. <https://doi.org/10.1007/s10661-018-6659-6>
22. Haghbayan, S., & Tashayo, B. (2021). Integrating ground-based air quality monitoring stations with mobile sensor units to improve the accuracy of PM2.5 concentration modeling. *Sepehr*. <https://doi.org/10.22131/sepehr.2021.242859>
23. Christakis, I., Stavrakas, I., Hloupis, G., & Tsakiridis, O. (2020, September). Low cost sensor implementation and evaluation for measuring NO₂ and O₃ pollutants. In 2020 9th International Conference on Modern Circuits and Systems Technologies (MOCAST) (pp. 1–4). IEEE. <https://doi.org/10.1109/MOCAST49295.2020.9200245>
24. Sudhira, H. S., Ramachandra, T. V., & Jagadish, K. S. (2003). Urban sprawl pattern recognition and modeling using GIS. *map India*, 2003, 28-31.
25. Mozumder, C., Reddy, K. V., & Pratap, D. (2013). Air pollution modeling from remotely sensed data using regression techniques. *Journal of the Indian Society of Remote Sensing*, 41(2), 269–277. <https://doi.org/10.1007/s12524-012-0235-2>
26. Sohrabinia, M., & Khorshidoust, A. M. (2007). Application of satellite data and GIS in studying air pollutants in Tehran. *Habitat International*, 31(2), 268–275. <https://doi.org/10.1016/j.habitatint.2007.02.003>
27. Wijeratne, I. K., & Bijker, W. (2006). Mapping dispersion of urban air pollution with remote sensing. In ISPRS Vienna 2006 Symposium (pp. 125–130). International Society for Photogrammetry and Remote Sensing (ISPRS).
28. Zoran, M. A., & Zoran, L. F. V. (2005). Mapping of dispersion of urban air pollution using remote sensing and in-situ monitoring data. *Proceedings of SPIE*, 5979, Remote Sensing of Clouds and the Atmosphere X, 597914. <https://doi.org/10.1117/12.627775>
29. Goheer, M. A., Hassan, S. S., Sheikh, A. S., Malik, Y., Uzair, M., & Satti, T. N. (2025). Assessing smog trends and sources of air pollutants across northeastern districts of Punjab, Pakistan using geospatial techniques. *International Journal of Environmental Science and Technology*, 22, 3657–3674. <https://doi.org/10.1007/s13762-024-05236-9>
30. Nguyen, X. T., Le, T. T., Nguyen, K. H., Nguyen, T. T. T., & Luu, T. P. K. (2025). Assessing air pollution and seasonal variations in Dong Nai Province, Vietnam: A geospatial analysis of key air quality parameters (2022–2023). *Urban Climate*, 45, 102475. <https://doi.org/10.1016/j.uclim.2025.102475>



31. Tikader, M., Mukhopadhyay, D., & Islam, M. Z. (2023). Role of Remote Sensing and GIS in mitigating Particulate Matters that intensify Air pollution in India: A Review. *Bulletin of Environment, Pharmacology and Life Sciences*, 12(10), 402–418.
32. Tikader, M., Mukhopadhyay, D., & Dabhadker, K. (2024). Remote sensing and GIS in air pollution mitigation: A bibliometric review of Chhattisgarh, India. *International Journal of Environment and Climate Change*. <https://doi.org/10.9734/ijecc/2024/v14i44106>
33. Munir, S., Gabr, S. S., Habeebulah, T. M., & Janajrah, M. A. (2016). Spatiotemporal analysis of fine particulate matter (PM_{2.5}) in Saudi Arabia using remote sensing data. *The Egyptian Journal of Remote Sensing and Space Science*, 19(2), 195–205. <https://doi.org/10.1016/j.ejrs.2016.06.001>
34. Ehrampoush, M., Jamshidi, S., Sakhvidi, M. Z., & Miri, M. (2017). A comparison on function of kriging and inverse distance weighting models in PM10 zoning in urban area. *Journal of Environmental Health and Sustainable Development*, 2(2), 379–387.
35. Oliver, M. A., & Webster, R. (1990). Kriging: a method of interpolation for geographical information systems. *International Journal of Geographical Information Systems*, 4(3), 313–332. <https://doi.org/10.1080/02693799008941549>
36. Webster, R., & Oliver, M. A. (2007). *Geostatistics for environmental scientists* (2nd ed.). Wiley. <https://doi.org/10.1002/9780470517277>
37. Liao, D., Peuquet, D., Duan, Y., Whitsel, E., Dou, J., Smith, R. L., Lin, H., Chen, J., & Heiss, G. (2006). GIS approaches for the estimation of residential-level ambient PM concentrations. *Environmental Health Perspectives*, 114(9), 1374–1380. <https://doi.org/10.1289/ehp.9169>
38. Hengl, T., Heuvelink, G. B. M., & Stein, A. (2004). A generic framework for spatial prediction of soil variables based on regression-kriging. *Geoderma*, 120(1–2), 75–93. <https://doi.org/10.1016/j.geoderma.2003.08.018>
39. Karimi, B., & Shokrinezhad, B. (2021). Spatial variation of ambient PM_{2.5} and PM₁₀ in the industrial city of Arak, Iran: A land-use regression. *Atmospheric Pollution Research*. <https://doi.org/10.1016/j.apr.2021.101235>
40. Ghaemi, Z., Alimohammadi, A., & Farnaghi, M. (2018). LaSVM-based big data learning system for dynamic prediction of air pollution in Tehran. *Environmental Monitoring and Assessment*, 190, 300. <https://doi.org/10.1007/s10661-018-6659-6>
41. Ministry of Environment, Water, and Agriculture. (2020). Executive regulations for air quality. Retrieved from <https://www.mewa.gov.sa/ar/InformationCenter/DocsCenter/RulesLibrary/Pages/default.aspx>.
42. Farahani, V. J., Altuwayjiri, A., Pirhadi, M., Verma, V., Ruprecht, A., Diapouli, E., Eleftheriadis, K., & Sioutas, C. (2022). The oxidative potential of particulate matter (PM) in different regions around the world and its relation to air pollution sources. *Environmental Science*, 2(5), 1076–1086. <https://doi.org/10.1039/d2ea00043a>
43. Alharbi, B., Shareef, M. M., & Husain, T. (2015). Study of chemical characteristics of particulate matter concentrations in Riyadh, Saudi Arabia. *Arabian Journal of Chemistry*, 8(1), 1–10. <https://doi.org/10.1016/j.arabjc.2015.01.001>



- Journal for Science and Engineering, 40(10), 2851–2863.
<https://doi.org/10.5094/APR.2015.011>
42. Harris, C. R., Millman, K. J., van der Walt, S. J., et al. (2020). Array programming with NumPy. *Nature*, 585, 357–362. <https://doi.org/10.1038/s41586-020-2649-2>.
43. Pedregosa, F., Varoquaux, G., Gramfort, A., et al. (2011). Scikit-learn: Machine learning in Python. *Journal of Machine Learning Research*, 12, 2825–2830.
44. Moore, D. S., McCabe, G. P., & Craig, B. A. (2012). *Introduction to the practice of statistics* (7th ed.). W.H. Freeman.
45. الزهراني، س. س. م. (2022). التوزيع المكاني لتركيز الجسيمات العالقة الدقيقة (PM2.5) و (PM10) و علاقتها بعناصر المناخ، وحدود ترتكزهما بمدينة الرياض. *مجلة جامعة الجوف للعلوم الإنسانية*, 210-13, 243. <http://search.mandumah.com/Record/1279910> مسترجع من