

تحليل الخصائص الهيدروغرافية والبيوجيوكيميائية بجنوب المتوسط باستخدام التعلم غير المُراقب وأثرها على البيئة البحرية

أشرف محمد عبدالله مرقب*

قسم الجغرافيا، كلية الآداب، جامعة الزاوية، ليبيا

*البريد الإلكتروني (للباحث المرجعي): a.mergb@zu.edu.ly

Analysis of Hydrographic and Biogeochemical Characteristics in the Southern Mediterranean Using Unsupervised Learning and Their Impact on the Marine Environment

Ashraf Mohammed Abdullah mergb *

Department of Geography, Faculty of Arts, University of Zawia, Libya

Received: 15-07-2025; Accepted: 12-09-2025; Published: 09-10-2025

المخلص

يهدف هذا البحث إلى تحليل وتوصيف الخصائص الهيدروغرافية والبيوجيوكيميائية في جنوب البحر الأبيض المتوسط، لفهم أنماط الطبقة العمودية وتأثيرها على البيئة البحرية. حيث تم تطبيق تقنيات التعلم غير المُراقب (Unsupervised Learning)، تحديداً خوارزميتي K-Means وخرائط التنظيم الذاتي (SOM)، لتحليل البيانات متعددة الأبعاد ودُعم هذا التحليل بأدوات إحصائية متقدمة مثل تحليل المكونات الرئيسية (PCA) وتحليل التباين (ANOVA) لضمان موثوقية النتائج.

نجح التحليل في تحديد ثلاثة تجمعات مائية رئيسية متميزة عمودياً (سطحية، متوسطة، وعميقة) أكد تحليل PCA أن الطبقة العمودية (المتماثلة في الكثافة، الحرارة، والأكسجين الذائب) هي المحرك الأساسي للتباين في المنطقة، كما أظهرت النتائج وجود فروق إحصائية ذات دلالة عالية في المتغيرات الفيزيائية والأكسجين الذائب بين التجمعات.

أثبتت البحث أن دمج التعلم الآلي مع التحليل الإحصائي يوفر إطاراً قوياً لاستكشاف الأنماط المعقدة في النظم البحرية، مما يدعم جهود الإدارة البيئية والحفاظ على الموارد البحرية في جنوب المتوسط.

الكلمات المفتاحية: التعلم غير المُراقب - الخصائص الهيدروغرافية - الخصائص البيوجيوكيميائية - البحر الأبيض .

Abstract

This research aims to analyze and characterize the hydrographic and biogeochemical properties of the southern Mediterranean Sea to better understand the patterns of vertical stratification and their impact on the marine environment.

Unsupervised learning techniques — specifically the K-Means algorithm and Self-Organizing Maps (SOM) — were applied to analyze multidimensional datasets. This analysis was further

supported by advanced statistical tools such as Principal Component Analysis (PCA) and Analysis of Variance (ANOVA) to ensure the reliability of the results.

The analysis successfully identified three major water masses that are vertically distinct (surface, intermediate, and deep layers). PCA results confirmed that vertical stratification — represented by density, temperature, and dissolved oxygen — is the main driver of variability in the region. The findings also revealed statistically significant differences in physical parameters and dissolved oxygen among the identified water masses.

The study demonstrated that integrating machine learning with statistical analysis provides a robust framework for exploring complex patterns in marine systems, thereby supporting environmental management and the conservation of marine resources in the southern Mediterranean.

Keywords: Unsupervised Learning, Hydrographic Properties, Biogeochemical Characteristics, Mediterranean Sea.

المقدمة

تُعد البيانات البحرية من أكثر الأنظمة البيئية تعقيداً وديناميكية حيث أنها تتأثر بمجموعة واسعة من العوامل الفيزيائية والكيميائية والبيولوجية، ويُشكل البحر الأبيض المتوسط حوضاً شبه مغلق كمنطقة دراسة فريدة نظراً لخصائصه الهيدروغرافية المميزة وتنوعه البيولوجي الغني، فضلاً عن تعرضه لضغوط بشرية متزايدة. ففهم الأنماط والخصائص الهيدروغرافية والبيوجيوكيميائية أمراً مهماً لتقييم صحة النظام البيئي البحري، وتحديد المناطق الحساسة، وتطوير استراتيجيات فعالة للإدارة والحفاظ على الموارد البحرية. لطالما اعتمدت الدراسات في علم المحيطات على التحليلات الإحصائية الوصفية والاستنتاجية لفهم العلاقات بين المتغيرات البيئية ومع ذلك فإن الطبيعة المعقدة للبيانات البحرية، في العادة تكون متعددة الأبعاد وغير خطية، تتطلب أدوات تحليلية أكثر تطوراً.

فمع تقدم العلم، برزت تقنيات التعلم غير المراقب (Unsupervised Learning) كمنهجية قوية قادرة على الكشف عن الأنماط المخفية والتجمعات الطبيعية ضمن مجموعات البيانات الكبيرة دون الحاجة إلى معرفة مسبقة بالنتائج حيث تُقدم هذه التقنيات إمكانيات هائلة في علم المحيطات لتحديد المناطق البيوجغرافية المتميزة، وفهم التفاعلات المعقدة بين المتغيرات البيئية.

أهمية البحث

- تتجسد أهمية هذا البحث في عدة جوانب رئيسية، تسهم في تعزيز الفهم العلمي للبيئات البحرية وتوفير أدوات تحليلية متقدمة لدعم الإدارة البيئية المستدامة
- سد الفجوة المعرفية: على الرغم من الأبحاث العديدة التي تناولت البحر الأبيض المتوسط، لا يزال هناك نقص في الدراسات التي تستخدم تقنيات التعلم غير المراقب
- فهم التفاعلات المعقدة (مثل درجة الحرارة، الملوحة، الكثافة) مع العوامل الكيميائية (مثل الأكسجين، المغذيات) بطرق معقدة وغير خطية، مثل SOM
- تحديد المناطق البيوجغرافية من خلال تطبيق تحليل التجميع، يمكن لهذا البحث أن يساهم في تحديد وتصنيف الكتل المائية أو المناطق التي تظهر خصائص بيئية متجانسة
- تطوير المنهجيات التحليلية: يُظهر هذا البحث كيفية دمج تقنيات التعلم غير المراقب مع التحليلات الإحصائية التقليدية (PCA, ANOVA) لتقديم تحليل شامل ومتكامل للبيانات البحرية.

أهداف البحث

يهدف هذا البحث إلى تحقيق الآتي

1. تحليل وتوصيف البيانات الهيدروغرافية والبيوجيوكيميائية) درجة الحرارة، الملوحة، الكثافة، الأكسجين الذائب، الفوسفات، النترات السيليكات في جنوب البحر المتوسط عبر أعماق مختلفة ومعرفة مدى تأثيرها على النظام البيولوجي البحري.
2. تطبيق تقنيات التعلم غير المراقب متمثلة في استخدام خوارزميات تحليل التجميع (Clustering Analysis) مثل K-Means و خرائط التنظيم الذاتي (Self-Organizing Maps - SOM) للكشف عن الأنماط المخفية والتجمعات ضمن البيانات متعددة الأبعاد
3. الكشف عن التجمعات والمناطق البيوجغرافية المتميزة في جنوب البحر الأبيض المتوسط بناءً على الخصائص الهيدروغرافية والبيوجيوكيميائية، وتحديد الخصائص المميزة لكل تجمع.
4. تطبيق التحليلات الإحصائية المتقدمة مثل تحليل المكونات الرئيسية (PCA) وتحليل التباين (ANOVA) للتحقق من صحة التجمعات والأنماط المكتشفة بواسطة التعلم غير المراقب، وتقديم تفسير كمي للعلاقات بين المتغيرات البيئية
5. معالجة القيم الشاذة والقيود: مناقشة ومعالجة القيم السالبة للفوسفات وثبات قيم السيليكات. في البيانات، وتوضيح كيفية التعامل معها في التحليل وتأثيرها على النتائج.

فرضيات البحث

الفرضية الأولى: توجد تجمعات ومناطق بيوجغرافية متميزة في جنوب البحر الأبيض المتوسط

الفرضية الثانية: ستظهر هذه التجمعات والمناطق البيوجغرافية أنماطاً أفقية رأسية مميزة تعكس التباين في الظروف البيئية عبر عمود الماء.

الفرضية الثالثة: ستؤكد التحليلات الإحصائية المتقدمة (ANOVA و PCA) صحة التجمعات والأنماط المكتشفة بواسطة التعلم غير المراقب، وستوفر تفسيراً كمياً للعلاقات بين المتغيرات البيئية الرئيسية.

الادوات المستخدمة

تم استخدام لغة البرمجة بايثون (Python) لإجراء المعالجات والتحليلات الإحصائية والتمثيل البياني، وذلك باستخدام مجموعة من المكتبات المتخصصة، من أبرزها:


1. NumPy: لمعالجة البيانات العددية.
2. Pandas: لتنظيم البيانات وتحليلها.
3. Matplotlib و Seaborn: لإنشاء الرسوم البيانية والتصورات.
4. Xarray و netCDF4: للتعامل مع ملفات NetCDF.

المنهجية المتبعة

تتبع هذه الدراسة منهجية بحثية متعددة الخطوات لضمان تحليل شامل للبيانات الفيزيائية والكيميائية، والكشف عن الأنماط والخصائص الهيدروغرافية والبيوجيوكيميائية في جنوب البحر الأبيض المتوسط، وتتضمن المنهجية جمع البيانات، ومعالجتها الأولية، وتطبيق تقنيات التعلم غير المراقب بالإضافة إلى التحليلات الإحصائية المتقدمة والتصورات الجغرافية

تحديد منطقة الدراسة

تم اختيار المنطقة الجنوبية للبحر الأبيض المتوسط أي المنطقة المحصورة بين دائرتي عرض 31 إلى 36 درجة شمالاً والمطلّة على السواحل الليبية.



الخريطة 1 منطقة الدراسة من اعداد الباحث باستخدام مكتبة matplotlib في لغة البرمجة Python.

جمع البيانات

تم الاعتماد في هذه الدراسة على مجموعة بيانات محددة للخصائص الفيزيائية والكيميائية للمياه في جنوب البحر الأبيض المتوسط تتضمن البيانات المتغيرات التالية
درجة الحرارة ($^{\circ}\text{C}$) مقياس لدرجة حرارة المياه الملوحة (PSU) مقياس لتركيز الأملاح الذائبة في المياه الكثافة (kg/m^3) مقياس لكتلة المياه لكل وحدة حجم، وتأثرها بدرجة الحرارة والملوحة
الأكسجين الذائب (ml/l) تركيز الأكسجين المذاب في المياه، وهو مؤشر حيوي لصحة النظام البيئي
الفوسفات أحد المغذيات الأساسية التي تلعب دوراً حاسماً في الإنتاجية الأولية النيترات مغذٍ أساسي آخر يدعم نمو العوالق النباتية السيليكا مغذٍ مهم لبعض أنواع العوالق النباتية التي تبني هيكلها من السيليكا
تم جمع هذه البيانات عبر نطاقات عمق مختلفة، مما يسمح بتحليل التغيرات الرأسية للخصائص.

الجدول (1) متوسطات تركيز العناصر في مياه جنوب البحر المتوسط

مجموعة العمق (متر)	درجة الحرارة ($^{\circ}\text{C}$)	الملوحة (PSU)	الكثافة (Kg/m^3)	الأكسجين المذاب (ml/l)	الفوسفات ($\mu\text{mol/l}$)	النيترات ($\mu\text{mol/l}$)	السيليكا ($\mu\text{mol/l}$)
0 - 100	14.31	38.29	212.0	0.71	-0.12	0.01	0.03
100 - 300	14.25	38.62	182.3	0.05	-0.08	0.03	0.03
300 - 600	14.10	38.74	174.4	0.02	-0.02	0.00	0.03
600 - 1000	13.93	38.72	176.0	0.02	-0.02	0.01	0.03
1000 - 1500	13.44	38.57	182.0	0.01	-0.01	0.00	0.03
1500 - 2000	13.41	38.51	188.0	0.03	-0.00	0.01	0.03
2000 - 3000	13.41	38.50	190.0	0.03	-0.02	0.01	0.03

المصدر: كوبرنيكوس الأوروبية لمراقبة البيئة البحرية لسنة 2023 (Copernicus Marine Environment Monitoring Service - CMEMS)

معالجة البيانات

قبل تطبيق أي تحليلات، تم إجراء معالجة أولية للبيانات لضمان جودتها وملاءمتها للتحليل

- التحقق من القيم المفقودة والشاذة: تم فحص مجموعة البيانات لتحديد أي قيم مفقودة أو شاذة نظراً لطبيعة البيانات المتاحة قيم متوسطة عبر نطاقات عمق لم تكن هناك قيم مفقودة صريحة ومع ذلك، تم التعامل مع القيم السالبة للفوسفات بشكل خاص

● **معالجة القيم السالبة للفوسفات:** لوحظ وجود قيم سالبة للفوسفات في بعض نطاقات العمق (مثل - 0.12). تُعد هذه القيم غير منطقية من الناحية البيولوجية وتشير عادةً إلى أخطاء في القياس أو تراكيز منخفضة جدًا قريبة من حد الكشف للأجهزة ولأغراض هذا التحليل، تم التعامل مع جميع القيم السالبة للفوسفات على أنها صفر لضمان عدم تأثير القيم غير الواقعية سلبًا على التحليلات الإحصائية وخوارزميات التعلم غير المراقب، مع الاعتراف بأن التراكيز الفعلية قد تكون منخفضة جدًا ولكنها ليست سالبة.

● **التحقق من ثبات قيم السيليكات:** لوحظ ثبات نسبي في قيم السيليكات عبر جميع نطاقات العمق على الرغم من أن هذا قد يشير إلى أن السيليكات ليست عاملاً متباينًا بشكل كبير في هذه المجموعة من البيانات، إلا أنها لم تُستبعد من التحليل الأولي سيتم تقييم تأثير هذا الثبات على نتائج التحليلات المتقدمة مثل (PCA) ومناقشة ما إذا كانت تساهم بشكل فعال في تمييز التجمعات.

● **تطبيع البيانات لضمان أن جميع المتغيرات تساهم بشكل متساوي في خوارزميات التعلم غير المراقب والتحليلات الإحصائية،** تم تطبيع البيانات حيث يمنع تطبيع المتغيرات ذات النطاقات الكبيرة من السيطرة على المتغيرات ذات النطاقات الأصغر تم استخدام طريقة (Zscore) حيث يتم تحويل كل قيمة معيارية إلى عدد الانحرافات المعيارية بعيدًا عن المتوسط.

❖ **تقنيات التعلم غير المراقب:** تم تطبيق تقنيتين رئيسيتين للتعلم غير المراقب للكشف عن الأنماط والتجمعات في البيانات

1. تقنيات التعلم غير المراقب (Unsupervised Learning Techniques)

تم توظيف تقنيتين رئيسيتين من تقنيات التعلم غير المراقب بهدف الكشف عن الأنماط والتجمعات داخل البيانات، وتُعد تقنية تحليل التجميع باستخدام K-Means من أكثر أساليب التجميع شيوعًا وفعالية، حيث يهدف إلى تقسيم مجموعة من نقاط البيانات إلى عدد معين مسبقًا من التجمعات (Clusters)، بحيث تكون النقاط داخل كل تجمع أكثر تشابهًا فيما بينها، وأقل تشابهًا مع النقاط في التجمعات الأخرى يعتمد هذا الأسلوب على تقليل مجموع مربعات المسافات بين كل نقطة بيانات ومركز التجمع الذي تنتمي إليه (Centroid)، وفي هذه الدراسة، لم يتم تحديد عدد التجمعات بشكل مسبق، بل تم استخدام طريقة الكوع (Elbow Method) لتقدير العدد الأمثل للتجمعات كما تم استخدام مؤشر الصورة (Silhouette Score) للتحقق من جودة التجمعات وضمان أن العدد المختار يعكس البنية الطبيعية للبيانات بشكل أفضل.

2. **خرائط التنظيم الذاتي (SOM: Self-Organizing Maps)** تعد خرائط التنظيم الذاتي (SOM) نوعًا من الشبكات العصبية الاصطناعية غير المراقبة، تُستخدم بشكل أساسي في تقليل الأبعاد وتصور البيانات متعددة المتغيرات حيث تقوم SOM بتحويل المدخلات ذات الأبعاد العالية إلى تمثيل منخفض الأبعاد، عادةً ما يكون في شكل خريطة ثنائية الأبعاد، مع الحفاظ على العلاقات الطوبولوجية بين البيانات الأصلية تتكون SOM من مجموعة من العقد العصبية (Neurons) التي تتكيف مع أنماط البيانات المدخلة وتمكن هذه الشبكات من الكشف عن الأنماط المعقدة والعلاقات غير الخطية بين المتغيرات، كما تُسهم في تحديد المناطق التي تتشابه في الخصائص داخل مجموعة البيانات يتم تدريب SOM على تمثيل البيانات بشكل فعال، حيث تُستخدم خريطة المكونات (Component Planes) وخريطة المسافة الموحدة (U-Matrix) لتحليل العلاقات بين المتغيرات فتُساعد هذه الخرائط في تحديد التجمعات (Clusters) وفهم البنية الكامنة في البيانات.

3. التحليل الإحصائي المتقدم (Advanced Statistical Analysis)

لدعم فهم الأنماط المكتشفة عبر تقنيات التعلم غير المراقب والتحقق من موثوقيتها، تم إجراء عدد من التحليلات الإحصائية المتقدمة مثل :

1. تحليل المكونات الرئيسية (PCA: Principal Component Analysis):

تُعد تقنية PCA من أدوات تقليل الأبعاد المهمة، حيث تعمل على تحويل مجموعة من المتغيرات المترابطة إلى عدد أقل من المتغيرات غير المترابطة تُعرف بـ "المكونات الرئيسية" وتهدف هذه التقنية إلى تحديد المتغيرات التي تفسر أكبر قدر ممكن من التباين في البيانات.

في هذه الدراسة، تم استخدام PCA لتحديد المتغيرات الفيزيائية والكيميائية التي تسهم بشكل بارز في التباين الكلي، كما تم توظيفها لتصوير العلاقات بين نقاط البيانات والمتغيرات ضمن فضاء منخفض الأبعاد وساهمت نتائج هذا التحليل في تفسير التجمعات التي تم اكتشافها باستخدام خوارزميات التعلم غير المراقب.

2. تحليل التباين (ANOVA: Analysis of Variance):


يُستخدم اختبار ANOVA لمقارنة متوسطات مجموعتين أو أكثر، بهدف تحديد ما إذا كانت هناك فروق ذات دلالة إحصائية بينها، ولقد تم تطبيق ANOVA لمقارنة متوسطات المتغيرات الفيزيائية والكيميائية بين التجمعات المختلفة التي تم تحديدها باستخدام خوارزميات K-Means و SOM وقد ساعدت نتائج ANOVA في التحقق من صحة هذه التجمعات، وتأكيد ما إذا كانت الخصائص المميزة لكل تجمع تختلف بشكل إحصائي معنوي عن التجمعات الأخرى

أولاً :- التحليل الوصفي للخصائص الفيزيائية والكيميائية


تُظهر البيانات المجمعة تبايناً واضحاً في الخصائص الفيزيائية والكيميائية عبر نطاقات العمق المختلفة، مما يعكس التدرجات العمودية المميزة لعمود الماء في البيئات البحرية

درجة الحرارة، الملوحة، والكثافة


تتناقص درجة الحرارة تدريجياً مع العمق، حيث سُجلت أعلى قيمة في الطبقة السطحية (0-100 متر) بمتوسط 14.31°C ، لتتخفض إلى حوالي 13.41°C في الأعماق الكبيرة (1500-2000 متر)؛ ويعود هذا التدرج إلى امتصاص الطبقات السطحية للطاقة الشمسية، أما الملوحة، فبلغت ذروتها في الطبقات المتوسطة (38.74 PSU)، ثم انخفضت تدريجياً إلى حوالي (38.50 PSU) عند عمق 2000-3000 متر تتراوح الكثافة بين 1021.0 kg/m^3 في الطبقة السطحية (0-100م) وتزداد تدريجياً مع العمق لتصل إلى حوالي 1029.0 kg/m^3 عند الأعماق الكبيرة (2000-3000م) أما في الطبقات المتوسطة (300-1000م) فقد سُجلت أعلى زيادة ملحوظة في الكثافة، حيث تتدرج من 1024.3 إلى 1026.0 kg/m^3 .



الشكل (1) يوضح العلاقة بين درجة حرارة الماء وعمق درجة القياس




الشكل (2) يوضح تغير كثافة المياه بالعمق المقاس



الشكل (3) يوضح مدى تركيز الملوحة في الماء مقابل العمق

الأكسجين الذائب


وصل تركيز الأكسجين الذائب إلى أعلى مستوياته في الطبقة السطحية نتيجة التبادل الغازي مع الغلاف الجوي والنشاط الضوئي. ومع ذلك، شهد تركيز الأكسجين انخفاضًا حادًا في الطبقات المتوسطة (0.05 ml/l عند 300-100 متر، و 0.02 ml/l عند 1000-300 متر)، وهي ما تُعرف بـ "منطقة الحد الأدنى للأكسجين" (OMZ)، حيث يستهلك الأكسجين بكثافة بفعل التحلل البيولوجي للمواد العضوية. في المقابل، ارتفع تركيز الأكسجين مرة أخرى في الأعماق الأكبر (3000-1500 متر) ليصل إلى حوالي 0.03 مما يشير إلى تأثير دوران المياه العميقة وإمداد هذه الطبقات بمياه غنية بالأكسجين.



الشكل (4) يوضح مدى تركيز الأكسجين المذاب في الماء مقابل العمق

الفوسفات والسيليكا

تُظهر الفوسفات أنماطاً متباينة عبر عمود الماء. بعد معالجة القيم الشاذة، تظل تراكيز الفوسفات منخفضة جداً بشكل عام. ومع ذلك، لوحظ ارتفاع طفيف في التركيز عند أعماق تتراوح بين 300-600 متر و1000-1500 متر. قد يشير هذا الانخفاض العام، والارتفاعات الطفيفة، إلى استهلاك المغذيات بشكل شبه كامل في هذه الطبقات، أو إلى أن النيتروجين هو العامل المحدد الأساسي أما السيليكا، فتُظهر قيمة ثابتة تبلغ 10.03 عبر جميع الأعماق. قد يدل هذا الثبات على أن السيليكا ليست عاملاً مقيداً رئيسياً في هذه البيئة البحرية، أو أن هناك توازناً مستمراً بين مصادرها ومصارفها.



الشكل (4) يوضح مدى تركيز الفوسفات والسيليكا في الماء مقابل العمق

نتائج تطبيق التعلم غير المراقب: الكشف عن التجمعات الطبيعية والأنماط المخفية لتوزيع بيانات العناصر لكشف التجمعات الطبيعية والأنماط المخفية ضمن مجموعات البيانات متعددة الأبعاد، تم تطبيق خوارزميتين للتعلم غير المراقب (خوارزميات التنظيم الذاتي (SOM) وتجميع-ك المتوسطات (K-Means) حيث توفر هذه النتائج نظرة واضحة حول كيفية تجميع نقاط البيانات بناءً على تشابه خصائصها الفيزيائية والكيميائية.

تحليل تجميع-ك المتوسطات (K-Means Clustering)

تجميع-ك المتوسطات هي خوارزمية تعلم آلة غير مراقب تقوم بتقسيم 'ن' ملاحظة إلى 'ك' مجموعة، حيث تنتمي كل ملاحظة إلى المجموعة الأقرب إلى متوسطها (المركز) الهدف من تجميع-ك المتوسطات هو تحديد هذه المراكز 'ك'، بحيث يمثل كل مركز قلب مجموعته.

كيف يعمل تجميع-ك المتوسطات:

- التهيئة (Initialization): تبدأ الخوارزمية باختيار 'ك' نقطة بيانات عشوائية كمراكز أولية للمجموعات.
- التخصيص (Assignment): يتم بعد ذلك تخصيص كل نقطة بيانات إلى أقرب مركز، لتشكيل 'ك' مجموعة أولية.
- التحديث (Update): بعد تخصيص جميع نقاط البيانات، تعيد الخوارزمية حساب موقع كل مركز عن طريق أخذ متوسط جميع نقاط البيانات المخصصة لتلك المجموعة.
- التكرار (Iteration): يتم تكرار الخطوتين 2 و 3 بشكل متكرر حتى تتوقف تخصيصات المجموعات عن التغير، أو يتم الوصول إلى الحد الأقصى لعدد التكرارات التي ان يشير هذا التقارب إلى أن المراكز قد استقرت، وأن المجموعات محددة جيداً.

مثلاً--- لو لدينا مجموعة واسعة من البيانات البيئية التي جمعناها من مواقع مختلفة في جميع أنحاء ليبيا قد تتضمن هذه البيانات معلومات من محطات مراقبة جودة الهواء، أو مواقع أخذ عينات التربة، أو نقاط رصد التنوع البيولوجي ويكون الهدف هو تجميع هذه المواقع معاً بناءً على خصائصها البيئية المشتركة هنا يمكننا استخدام تقنية مثل "تجميع متوسطات العوامل البيئية" للتحديد، على سبيل المثال، المناطق التي تتميز بمستويات متشابهة من تلوث الهواء كما يمكن تحديد المناطق التي تتشارك فيها خصائص تربة معينة مثل الحموضة أو الملوحة أو الخصوبة، بالإضافة إلى ذلك، تساعد هذه الطريقة في تصنيف المناطق التي تظهر أنماطاً متشابهة من الغطاء النباتي والتنوع البيولوجي.

بشكل أساسي، يمكن تحقيق ذلك من خلال تجميع نقاط المراقبة التي تتشارك في مؤشرات بيئية متشابهة. بعد تطبيق طريقة الكوع (Elbow Method) ومؤشر الصورة الظلية (Silhouette Score)، تم تحديد العدد الأمثل للمجموعات البيانات ليكون ثلاثة، تشير هذه المجموعات إلى وجود ثلاث طبقات مائية رئيسية متميزة في عمود الماء، بناءً على الخصائص المدروسة الجدول (2) يوضح الخصائص المتوسطة لكل مجموعة.

الجدول 2: الخصائص المتوسطة للمتغيرات في كل تجمع

درجة الحرارة (°C)	الملوحة (PSU)	الكثافة (kg/m³)	الأوكسجين الذائب (ml/l)	الفوسفات (µmol/l)	النترات (µmol/l)	السيليكا (µmol/l)	التجمع
13.42	38.5267	186.667	0.0233333	0	0.0066667	0.03	0
14.31	38.29	212	0.71	0	0.01	0.03	1
14.0933	38.6933	177.567	0.08	0	0.0133333	0.03	2

تفسير التجمعات المائية

تشير البيانات المقدمة إلى ثلاثة تجمعات مائية متميزة، يتميز كل منها بخصائص فيزيائية وكيميائية فريدة تعكس ظروفًا بيئية مختلفة داخل المسطح المائي.

التجمع 1 (الطبقة السطحية 0)

يتميز هذا التجمع بمتوسط درجة حرارة يبلغ 13.42°C وتركيز أكسجين ذائب منخفض جدًا قدره 0.0233333 ml/l وكثافة تبلغ 186.667 وملوحة قدرها 38.5267 ، تشير هذه الخصائص مجتمعة إلى أن التجمع 1 يمثل طبقات مياه أعمق وأكثر استقرارًا حيث يُعزى انخفاض تركيز الأكسجين الذائب غالبًا إلى ضعف التهوية وعمليات تحلل المواد العضوية المستمرة في الأعماق، مما يستهلك الأكسجين المتاح، كما أن استقرار درجة الحرارة يشير إلى عدم تأثر هذه الطبقات بالتقلبات السطحية.

التجمع 2 (الطبقة الانتقالية أو المتوسطة 1)


يتميز هذا التجمع بأعلى درجة حرارة مسجلة، حيث تبلغ 14.31°C ، بالإضافة إلى ذلك، يتميز بمتوسط أكسجين ذائب يبلغ 0.71 ml/l ، وكثافة تبلغ 212 وأقل ملوحة قدرها 38.29 التجمع 2 يمثل الطبقات السطحية للمياه تتأثر هذه الطبقات بشكل مباشر بالتبادل الغازي مع الغلاف الجوي وامتصاص ضوء الشمس، مما يؤدي إلى درجات حرارة أعلى وتركيزات أكسجين ذائب أعلى تدعم الإنتاجية الأولية العالية من خلال عملية التمثيل الضوئي. كما أن انخفاض الملوحة قد يكون نتيجة لهطول الأمطار أو تدفق المياه العذبة السطحية.

التجمع 3 (الطبقة العميقة 3)

يظهر هذا التجمع خصائص متوسطة بين التجمعين الأول والثاني، حيث يبلغ متوسط درجة حرارته 14.0933 وتركيز الأكسجين الذائب 0.03 ، وكثافة 177.567 PSU وملوحة 38.6933 ، تشير هذه الخصائص إلى أن التجمع 3 قد يدل طبقات انتقالية أو متوسطة بين الطبقات السطحية والأعمق، أو ربما منطقة تتأثر بعمليات الخلط العمودي حيث أن تركيز الأكسجين الذائب المنخفض نسبيًا مقارنة بالسطح يشير إلى استهلاك الأكسجين في هذه الطبقات، بينما درجة الحرارة المتوسطة توحى بوجود توازن بين التأثيرات السطحية والعميقة.

قد تشير خصائص هذا التجمع إلى درجة معينة من الخلط العمودي بين الطبقات السطحية والعميقة، خاصة خلال فصول معينة (مثل الشتاء في المناطق المعتدلة) حيث تنخفض درجات حرارة السطح وتزداد كثافتها، مما يؤدي إلى غوص المياه السطحية وخلطها مع المياه الأعمق وعلى الرغم من أن الأكسجين أعلى قليلًا من التجمع العميق، إلا أنه لا يزال منخفضًا نسبيًا قد يشير هذا إلى استهلاك مستمر للأكسجين بسبب تحلل المواد العضوية الغارقة من الطبقات السطحية المنتجة، أو نتيجة لضعف التهوية في هذه المنطقة المتوسطة. وتلعب هذه الطبقات دورًا في نقل المغذيات التي قد تتراكم من الطبقات العميقة هنا، أو قد تنتقل المغذيات من السطح إلى الأسفل.

إن فهم هذه التجمعات المائية من منظور بيئي يسمح بتقدير العمليات المعقدة التي تحدث في المسطحات المائية، من دورات المغذيات وديناميكيات الأكسجين إلى توزيع الكائنات الحية وإنتاجيتها تتأثر هذه التجمعات بشكل كبير بالعوامل المناخية والبشرية، وبالتالي فإن دراستها تسهم في تقييم صحة النظام البيئي ووضع استراتيجيات الإدارة المستدامة.



الشكل (5) استخدام PCA في توزيع نقاط البيانات في التجمعات (K-Means)

خرائط التنظيم الذاتي (SOMs)، أو خرائط كوهونين، هي شبكات عصبية اصطناعية غير خاضعة للإشراف تُستخدم لتبسيط وتصور البيانات المعقدة وعالية الأبعاد، تعمل على تحويل هذه البيانات إلى تمثيلات بصرية ثنائية الأبعاد، مما يساعد على اكتشاف الأنماط والتجمعات والعلاقات المخفية.

كيف تعمل خرائط التنظيم الذاتي (SOMs)
تعتمد آلية عمل الـ SOMs على التعلم التكراري، حيث تقوم العقد العصبية بتنظيم نفسها ذاتيًا لتمثيل الخصائص الإحصائية لبيانات الإدخال حيث تشمل مايلي
* **التهيئة:** تُنشأ شبكة ثنائية الأبعاد من العقد، لكل منها متجه وزن عشوائي بنفس أبعاد بيانات الإدخال.
يمكن تطبيق SOMs بفعالية على البيانات البيئية البحرية، مثل قياسات: درجة حرارة الماء، الملوحة، الأكسجين المذاب، الكلوروفيل-أ، العمق، والحموضة (pH)، وحتى الملوثات.


المنهجية التطبيقية:

- تجهيز البيانات: جمع ومعالجة البيانات من نقاط قياس بحرية متعددة (مثل تطبيع القيم).
- تدريب الـ SOM: استخدام هذه البيانات كمدخلات لتدريب شبكة SOM، حيث سَتُصنّف العقد لتمثل المناطق البحرية ذات الخصائص البيئية المتشابهة.
- تحليل لوحات المكونات: فحص لوحات المكونات لكل متغير بيئي. على سبيل المثال:
- لوحة درجة حرارة الماء سَتُظهر المناطق الدافئة أو الباردة.
- لوحة الكلوروفيل-أ سَتُبرز مناطق الإنتاجية البيولوجية العالية.
- يمكن تحديد المناطق ذات التركيزات العالية من الملوثات عبر لوحاتها المخصصة.

الاستنتاجات والفوائد:


- باستخدام الـ SOMs، يمكن لعلماء المحيطات:
- تحديد وتصنيف الموائ البحرية المتميزة بيئيًا، حتى لو كانت متباعدة جغرافيًا.
- فهم التفاعلات المعقدة بين العوامل البيئية المختلفة.

- رصد التغيرات البيئية مع مرور الوقت.
 - تحديد المناطق ذات الأهمية البيئية الخاصة لدعم جهود الحفظ والإدارة المستدامة.
- تُعد خرائط التنظيم الذاتي بذلك أداة تحليلية قوية لاستكشاف وفهم النظم البيئية البحرية المعقدة، مما يُساهم في دعم القرارات في الأبحاث البيئية البحرية والحفاظ عليها.



الشكل (6) : خرائط المكونات لشبكة (SOM) Component Planes

من خلال تحليل خرائط المكونات، يمكن ملاحظة أنماط واضحة للبيانات درجة الحرارة والأكسجين الذائب تُظهر أنماطاً متشابهة، حيث تُشير العقد ذات القيم العالية لدرجة الحرارة إلى قيم عالية للأكسجين، والعكس صحيح وهذا يدل إلى ارتباط قوي بينهما، حيث أن المياه الباردة والعميقة غالباً ما تكون أقل تشبعاً بالأكسجين والملوحة والكثافة تُظهر أيضاً أنماطاً متشابهة، حيث تُشير العقد ذات الملوحة العالية إلى كثافة عالية، مما يؤكد العلاقة الفيزيائية بينهما أما الفوسفات والنيتريت تُظهر هذه المغذيات أنماطاً متشابهة، مما يُشير إلى أنها غالباً ما تتواجد معاً وتستهلك أو يعاد تدويرها في عمليات بيوجيوكيميائية مماثلة أما السيليكا فتُظهر خريطة السيليكا نمطاً موحداً نسبياً عبر الخريطة، مما يؤكد ثبات قيمها وعدم مساهمتها الكبيرة في التباين العام للبيانات وتؤكد خريطة المسافة الموحدة (U-Matrix) لشبكة SOM وجود مناطق متميزة على الخريطة تُشير إلى التجمعات، فتُشكل المناطق ذات الألوان الداكنة مسافات عالية تكون حدوداً بين هذه التجمعات، مما يُعزز النتائج المستخلصة من K-Means حول وجود طبقات مائية متميزة



الشكل 9: خريطة المسافة الموحدة (U-Matrix) لشبكة SOM.

ثانيا التحليلات الاحصائية المتقدمة

تم استخدام تحليل المكونات الرئيسية (PCA) وتحليل التباين (ANOVA) للتحقق من صحة الأنماط المكتشفة بواسطة التعلم غير المراقب وتوفير تفسير كمي للعلاقات بين المتغيرات البيئية

- **نتائج تحليل المكونات الرئيسية (PCA)** تم تطبيق PCA على البيانات لتحديد المتغيرات التي تفسر أكبر قدر من التباين تُظهر نتائج أن المكونين الرئيسيين الأولين (PC1 و PC2). يفسران نسبة كبيرة من التباين الكلي في البيانات (الجدول التالي يوضح القيم الذاتية والتباين المفسر للمكونات الرئيسية

الجدول 3 قيمة التباين بين المكونين

الرئيسي المكون	الذاتية القيمة	التباين نسبة (%) المفسر	التباين نسبة (%) التراكمي
PC1	0.57951515	57.95	57.95
PC2	0.27013911	27.01	84.96

يتضح من الجدول

المكون الرئيسي الأول (PC1): تباين الطبقة العمودية

يمثل المكون الرئيسي الأول (PC1) النسبة الأكبر من التباين الكلي المفسر للبيانات، حيث يفسر 77.5% من هذا التباين تُظهر المتجهات الذاتية (Eigenvectors) لهذا المكون أن المتغيرات الفيزيائية مثل الكثافة (0.571915)، والأكسجين الذائب (0.563932)، ودرجة الحرارة (0.236847) لها تأثير كبير في تفسير هذا المكون.

تشير القيم العالية لدرجة الحرارة والأكسجين الذائب والقيم المنخفضة للكثافة إلى أحد أطراف طيف التباين الذي يمثل PC1 في المقابل، تشير القيم المنخفضة لدرجة الحرارة والأكسجين الذائب والقيم العالية للكثافة إلى الطرف الآخر من هذا الطيف. تُفسر هذه الديناميكية بأن PC1 يمثل بشكل أساسي التدرج العمودي

للتطبيقية في عمود الماء. يعكس هذا المكون الاستجابة المترابطة لهذه المتغيرات لتغيرات العمق، مما يشير إلى وجود طبقات مائية متميزة بناءً على الخصائص الفيزيائية والكيميائية.

المكون الرئيسي الثاني (PC2): تباين المغذيات والملوحة

يفسر المكون الرئيسي الثاني (PC2) نسبة إضافية من التباين قدرها 7.19%، مما يرفع التباين التراكمي المفسر بواسطة المكونين إلى 84.69%. تُظهر المتجهات الذاتية للمتغيرات على PC2 أن النترات (0.651189) والملوحة (0.287784) لهما تأثير كبير على هذا المكون.

يُرجح أن يمثل PC2 التباين في خصائص المغذيات والملوحة التي قد لا تكون مرتبطة بشكل مباشر بالتطبيقية الحرارية التي يمثلها PC1. هذا يشير إلى أن الاختلافات في تركيز النترات ومستويات الملوحة تمثل بعداً مستقلاً للتباين في النظام المائي، مما يوحي بتأثير عوامل أخرى مثل مصادر التلوث أو التغيرات في الميزانية المائية التي تؤثر على هذه المتغيرات بشكل منفصل عن عوامل التطبيقية الحرارية.

قدم تحليل المكونات الرئيسية هنا نظرة ثاقبة حول الأبعاد الرئيسية للتباين في خصائص العمود المائي. بينما يُمثل PC1 التدرجات العمودية المرتبطة بالتطبيقية، يُسلط PC2 الضوء على التباين في المغذيات والملوحة كعوامل مؤثرة بشكل مستقل. يُعزز هذا الفهم الشامل للتباينات الرئيسية في النظام المائي من القدرة على تحديد العمليات البيئية المهيمنة وتأثيرها على جودة المياه.

• تحليل ANOVA لبيانات المتغيرات الفيزيائية والكيميائية

تم إجراء تحليل ANOVA (تحليل التباين) لمقارنة المتوسطات بين التجمعات الثلاثة التي تم تحديدها باستخدام تقنية K-means. وقد أظهرت النتائج وجود فروق ذات دلالة إحصائية في بعض المتغيرات الفيزيائية والكيميائية بين هذه التجمعات، مما يدل على وجود اختلافات مهمة في الخصائص البيئية للتجمعات.

الجدول 4: نتائج تحليل ANOVA لمتغيرات الدراسة عبر التجمعات

النتيجة	الدلالة الإحصائية (Sig.)	قيمة F	المتغير
ذات دلالة إحصائية	0.000272069	36.3434	درجة الحرارة (°C)
ذات دلالة إحصائية	0.000671273	23.2524	الملوحة (PSU)
ذات دلالة إحصائية	0.000525787	25.582	الكثافة (kg/m³)
ذات دلالة إحصائية	0.00000764	7.923	الأكسجين الذائب (ml/l)
ليست ذات دلالة إحصائية	0.201	1.7011	الفوسفات (μmol/l)
ليست ذات دلالة إحصائية	0.790123	0.25	المقرات (كم)
ليست ذات دلالة إحصائية	NaN	NaN	السيليكا (μmol/l)

من الجدول السابق يتضح أن نتائج تحليل التباين أحادي الاتجاه أظهر فروقاً ذات دلالة إحصائية عالية ($p < 0.03$) في متوسطات كل من درجة الحرارة، والملوحة، والكثافة، والأكسجين الذائب بين التجمعات الثلاثة المدروسة. يشير هذا إلى أن هذه المتغيرات تساهم بشكل كبير في تمييز التجمعات عن بعضها البعض، وأن كل تجمع يتميز بخصائص فريدة فيما يتعلق بهذه المتغيرات الفيزيائية والكيميائية. هذا الاستنتاج يؤكد الدور المحوري لهذه المتغيرات في تحديد الهوية المميزة لكل تجمع مائي ضمن نطاق الدراسة.

على النقيض من ذلك، لم تُظهر قيم الفوسفات، والنترات، والسيليكا فروقاً ذات دلالة إحصائية ($p > 0.05$) بين التجمعات. يشير هذا إلى أن هذه المغذيات، ضمن مجموعة البيانات الحالية، لا تساهم بشكل كبير في الفصل بين التجمعات المائية. يعزز هذا الاستنتاج الملاحظات الأولية التي أشارت إلى ثبات نسبي في قيم السيليكا وانخفاض عام في قيم الفوسفات والنترات عبر جميع الأعماق التي تم أخذ العينات منها.

هذا يدل على أن هذه المغذيات قد لا تكون العوامل الرئيسية التي تحدد الفروق بين التجمعات في سياق هذه الدراسة.

الأهمية الإحصائية لنتائج تحليل التباين

بناءً على ما تقدم، توفر نتائج تحليل التباين (ANOVA) دعمًا إحصائيًا قويًا لتقسيم البيانات إلى التجمعات المكتشفة. كما أنها تسلط الضوء على المتغيرات الأكثر أهمية في تحديد هذه التجمعات، وهي في هذه الحالة درجة الحرارة، والملوحة، والكثافة، والأوكسجين الذائب. يمكن أن تُستخدم هذه النتائج كأساس للمزيد من التحليلات، مثل تحليل المتوسطات (Means) و تحليل المجموعات (K-means clustering)، لتأكيد التجمعات المحددة وتعميق فهمنا للعوامل التي تقود هذه الاختلافات

معالجة النواقص الثانوية

معالجة القيم السالبة للفوسفات: تُعد القيم السالبة للفوسفات التي لوحظت في البيانات تحدّيًا منهجيًا في هذا البحث، تم التعامل مع هذه القيم على أنها صفر، وهو نهج شائع في الدراسات البيئية عندما تكون التراكيز قريبة جدًا من حد الكشف أو عندما تُشير القيم السالبة إلى أخطاء في المعايرة أو القياس على الرغم من أن هذا النهج يسمح باستمرار التحليل، إلا أنه من المهم الإقرار بأن التفسير البيوجيوكيميائية الدقيق للتراكيز المنخفضة جدًا قد يتأثر في الدراسات المستقبلية، لذلك يجب التحقق من جودة البيانات بشكل أكثر صرامة، وربما استخدام طرق قياس أكثر حساسية، أو تطبيق تقنيات استيفاء (imputation) أكثر تعقيدًا إذا كانت القيم السالبة تشير إلى بيانات مفقودة أو غير موثوقة بدلاً من تراكيز حقيقية قريبة من الصفر. ومع ذلك، في سياق الكشف عن الأنماط الكبيرة والتجمعات، لم تؤثر هذه المعالجة بشكل جوهري على النتائج العامة المتعلقة بالأنماط البيوجغرافية

معالجة ثبات قيم السيليكات:

أظهرت قيم السيليكات ثباتًا ملحوظًا عبر جميع نطاقات العمق في البيانات المقدمة هذا الثبات قد يشير إلى أن السيليكات ليست عاملاً متباينًا بشكل كبير في هذه المنطقة أو في هذا الوقت من السنة، أو أن هناك توازنًا مستقرًا بين مصادرها ومصارفها. في تحليل ANOVA، لم تُظهر السيليكات فروقًا ذات دلالة إحصائية بين التجمعات، مما يؤكد أنها لم تساهم بشكل كبير في تمييز هذه التجمعات. هذا لا يعني بالضرورة أن السيليكات غير مهمة بيئيًا، ولكنها قد لا تكون المتغير الأكثر تمييزًا في هذه المجموعة من البيانات بالذات. في سياقات أخرى أو مع مجموعات بيانات أوسع، قد تُظهر السيليكات تباينًا أكبر وتلعب دورًا أكثر أهمية في تحديد الأنماط البيوجغرافية

مناقشة النتائج الرئيسية

1. أظهر التحليل الوصفي للبيانات تدرجات عمودية واضحة في معظم المتغيرات الفيزيائية والكيميائية و انخفاض درجة الحرارة والأوكسجين الذائب (DO) مع العمق، وزيادة الكثافة حيث تعكس هذه الأنماط الطبقة الحرارية والمحيطية، والتي تُعد أساسية لتحديد توزيع الكائنات البحرية يمكن أن تحد من تبادل الغازات والمغذيات بين الطبقات السطحية والعميقة، مما يؤثر على الإنتاجية الأولية وتوزيع الأنواع.
2. الانخفاض الحاد في الأوكسجين الذائب في الطبقات المتوسطة (منطقة الحد الأدنى للأوكسجين - OMZ) حيث تُعد مناطق الحد الأدنى للأوكسجين بيئات قاسية تحد من وجود الكائنات الحية التي تتطلب مستويات عالية من الأوكسجين توسع هذه المناطق، نتيجة لتغير المناخ والتلوث، يمكن أن يؤدي إلى فقدان الموائل، وتقليل التنوع البيولوجي، وتغيير في دورات المغذيات البحرية، مما يؤثر على مصايد الأسماك والنظم البيئية بأكملها.

3. أثبتت تقنيات التعلم غير المراقب، وتحديدًا خوارزميات K-Means وخرائط التنظيم الذاتي (SOM)، فعاليتها في الكشف عن التجمعات الطبيعية ضمن البيانات فقد تم تحديد ثلاث تجمعات رئيسية (سطحية، متوسطة، عميقة) بواسطة K-Means ويؤكد هذا التحديد وجود مناطق بيوجغرافية متميزة عمودياً، لكل منها خصائص فيزيائية وكيميائية فريدة ففهم هذه التجمعات ضروري لإدارة الموارد البحرية وحماية التنوع البيولوجي، حيث أن كل تجمع قد يدعم مجتمعات بيولوجية مختلفة تتكيف مع ظروفه الخاصة.
4. العلاقات بين المتغيرات عبر خرائط التنظيم الذاتي (SOM) تُمكن هذه الخرائط من فهم الأنماط الطبولوجية المعقدة بين المتغيرات، مما يساعد في تحديد العوامل البيئية الرئيسية التي تشكل الموائل البحري هذا الفهم المتعمق للعلاقات البيئية يمكن أن يدعم جهود الحفظ والتنبؤ بالتغيرات البيئية.
5. عززت التحليلات الإحصائية المتقدمة، مثل تحليل المكونات الرئيسية (PCA) وتحليل التباين (ANOVA)، النتائج المستخلصة من التعلم غير المراقب و تحديد المتغيرات الفيزيائية (درجة الحرارة، الملوحة، الكثافة) والأكسجين الذائب كمحركات رئيسية للتباين (PCA) حيث تُشير هذه النتائج إلى أن هذه المتغيرات هي العوامل الأساسية التي تحدد خصائص الكتل المائية وتوزيع الكائنات الحية فيها فمراقبة هذه المتغيرات أمر بالغ الأهمية لتقييم صحة المحيطات والتنبؤ بالاستجابات البيئية للتغيرات المناخية أو الأنشطة البشرية.
6. الفروق ذات الدلالة الإحصائية بين متوسطات المتغيرات الرئيسية بين التجمعات (ANOVA) تُضفي هذه الدلالة الإحصائية قوة على تمييز التجمعات البيوجغرافية، مما يؤكد أن هذه الطبقات ليست مجرد تقسيمات نظرية بل تمثل بيئات متميزة بخصائصها البيئية. هذا يدعم الحاجة إلى استراتيجيات إدارة وحماية مخصصة لكل منطقة بيوجغرافية.

الخاتمة

قدّم هذا البحث إطاراً تحليلياً يهدف لفهم الخصائص الفيزيائية والبيوجيوكيميائية للبيئات البحرية في جنوب البحر الأبيض المتوسط، من خلال توظيف تقنيات التعلم غير المراقب إلى جانب أدوات التحليل الإحصائي. وقد ساعد هذا المنهج في تنظيم البيانات المعقدة متعددة الأبعاد، وتصنيفها وفق أنماط محددة، دون افتراضات مسبقة، مما وفّر منظوراً موضوعياً لتوزيع الخصائص البيئية في المنطقة المدروسة. إن اعتماد هذا النهج يُمكن من قراءة البيانات البيئية بصورة أكثر عمقاً، ويُسهّل دراسة التفاعلات بين المتغيرات المختلفة، مثل درجة الحرارة، الملوحة، الكثافة، ومستويات المغذيات. وتكمن أهمية ذلك في دعم التحليلات المستقبلية المتعلقة بدديناميكيات النظم البحرية، دون الحاجة إلى الاعتماد فقط على الأساليب التقليدية التي قد تُغفل بعض التفاصيل الدقيقة أو الأنماط غير الظاهرة. هذا البحث لا يدّعي الإحاطة الشاملة بكافة الجوانب المرتبطة بالنظام البحري المدروس، لكنه يُوفّر قاعدة تحليلية يمكن البناء عليها في دراسات لاحقة. كما يوضح أن استخدام أدوات التحليل الحسابي غير التقليدية ليس مجرد خيار تقني، بل ضرورة علمية عند التعامل مع بيانات بيئية عالية التداخل والتعقيد.

المراجع

1. Belgacem, M., Sghaier, Y. R., Zouch, M., & Ayadi, H. (2020). On the peculiar nutrient ratios in the Mediterranean Sea: A basin-wide study. Progress in Oceanography, 188, 102424
2. Civitarese, G., Fajar, N. M., Fripiat, F., Gerke, L., Gogou, A., Guallart, E. F., ... & Tanhua, T. (2020). Physical and biogeochemical parameters of the

- Mediterranean Sea during the last few decades. *Earth System Science Data*, 12(4), 2747–2771. <https://doi.org/10.5194/essd-12-2747-2020>
3. Cremonini, R., Cappelletto, A., & Pavanati, M. (2021). K-means clustering for meteo-oceanographic data analysis: A case study. *Journal of Marine Science and Engineering*, 9(5), 521.
 4. Esri, National Oceanic and Atmospheric Administration (NOAA), & U.S. Geological Survey (USGS). (2017). A Three-Dimensional Mapping of the Ocean Based on Environmental Data. *Oceanography*, 30(2), 100-109.
 5. Grover, A., Benson, A. R., & Guttag, J. V. (2024). The Promise and Pitfalls of Machine Learning in Ocean Remote Sensing. *Oceanography*, 37(3). <https://tos.org/oceanography/article/the-promise-and-pitfalls-of-machine-learning-in-ocean-remote-sensing>
 6. Hassoun, A. E. R., & Mojtahid, M. (2025, September 5). What climate change means for the Mediterranean Sea. *Phys.org*. Retrieved from <https://phys.org/news/2025-09-climate-mediterranean-sea.html>
 7. Hassoun, A. E. R., et al. (2025). Climate change risks on key open marine and coastal Mediterranean ecosystems. *Scientific Reports*, 15, Article 07858. <https://www.nature.com/articles/s41598-025-07858-x>
 8. Monir, M. U., et al. (2023). Machine learning in marine ecology: an overview of techniques and applications. *ICES Journal of Marine Science*, 80(7), 1829–1847. <https://doi.org/10.1093/icesjms/fsad118>
 9. Placenti, F., Schroeder, K., Borghini, M., Cerrati, G., Cuttitta, A., Tancredi, V., ... & Patti, B. (2024). A 12-year-long (2010–2021) hydrological and biogeochemical dataset in the Sicily Channel (Mediterranean Sea). *Earth System Science Data*, 16(2), 743–757.