

## Smart Recommendation System for Tourists

Nour Abd Alhameed Khallof \*, Dr. Majida Albakoor

Syrian Virtual University | Syria

Received:

29/05/2025

Revised:

11/06/2025

Accepted:

23/06/2025

Published:

15/09/2025

\* Corresponding author:

[nourkhallof98@gmail.com](mailto:nourkhallof98@gmail.com)  
[m](https://orcid.org/0000-0001-9148-1000)

Citation: Khallof, N. A., & Albakoor, M. (2025).

Smart Recommendation

System for Tourists.

*Journal of engineering*

*sciences and information*

*technology*, 9(3), 88 –

110.

[https://doi.org/10.26389/](https://doi.org/10.26389/AJSRP.R010625)

[AJSRP.R010625](https://doi.org/10.26389/AJSRP.R010625)

2025 © AISRP • Arab

Institute for Sciences &

Research Publishing

(AISRP), United States, all

rights reserved.

• Open Access



This article is an open access article distributed under the terms and conditions of the Creative Commons Attribution (CC BY-NC) [license](https://creativecommons.org/licenses/by-nc/4.0/)

**Abstract:** This study aims to develop a smart recommendation system that assists tourists in selecting their travel destinations based on personal interests, by integrating artificial intelligence techniques in analyzing preferences and reviews. A comprehensive scientific methodology was adopted, beginning with the identification of user needs, followed by data collection on tourist attractions and user evaluations, and culminating in the design of a smart recommendation model based on the Matrix Factorization algorithm within the ML.NET framework.

Context awareness was incorporated to enhance the precision of suggestions. The system was developed using ASP.NET Core MVC and SQL Server, which contributed to the efficiency of the recommendations and improved user interaction. The proposed model demonstrated significant superiority in recommendation accuracy compared to traditional systems, helped reduce the confusion caused by an overload of options, and increased user satisfaction—affirming its effectiveness in supporting informed tourist decision-making and guiding travelers toward more personalized and satisfying experiences.

**Keywords:** Tourism recommendations, Artificial intelligence, Personalization User experience, Machine learning, Intelligent systems.

### نظام توصية ذكي للسائحين

نور عبد الحميد خلوّف\*، الدكتورة / ماجدة البكور

الجامعة الافتراضية السورية | سوريا

**المستخلص:** يهدف هذا البحث إلى تطوير نظام توصية ذكي يُعين السائحين على اختيار وجهاتهم السياحية استنادًا إلى اهتماماتهم الشخصية، من خلال توظيف تقنيات الذكاء الاصطناعي في تحليل التفضيلات والتقييمات. لتحقيق ذلك، تم اتباع منهجية علمية شاملة بدأت برصد احتياجات المستخدمين، مرورًا بجمع بيانات حول المعالم السياحية وتقييمات الزوار، وصولًا إلى تصميم نموذج توصية سياحي قائم على خوارزمية Matrix Factorization ضمن إطار عمل ML.NET، مع دمج عنصر الفهم السياقي (Context Awareness) لتعزيز دقة الاقتراحات.

وقد طُوّر النظام باستخدام بيئة ASP.NET Core MVC وقاعدة بيانات SQL Server، ما ساهم في تحسين فعالية التوصيات وتسهيل التفاعل مع المستخدم. أظهرت نتائج النموذج المقترح تفوقًا ملحوظًا من حيث دقة التوصية مقارنة بالأنظمة التقليدية، كما ساهم في تقليل الحيرة الناتجة عن كثرة الخيارات، ورفع مستوى رضا المستخدمين. مما يؤكد جدواه في دعم اتخاذ القرار السياحي وتوجيه السائحين نحو تجارب سفر أكثر ملاءمة ورضًا.

**الكلمات المفتاحية:** توصيات سياحية، ذكاء اصطناعي، تخصيص تجربة المستخدم، تعلم الآلة، نظم ذكية.

## 1. المقدمة Introduction:

تُعد السياحة من الركائز الأساسية في دعم الاقتصاد والتنمية الاجتماعية في العديد من دول العالم، حيث تسهم في رفع الناتج المحلي، وتوفير فرص العمل، وتنشيط قطاعات خدمية عديدة مثل الضيافة والنقل والتجارة. كما تلعب دورًا مهمًا في جذب الاستثمارات إلى المناطق التي تتمتع بمقومات طبيعية أو تاريخية مما يسهم في تحقيق تنمية إقليمية أكثر توازنًا، إلى جانب ذلك، تُعد السياحة وسيلة فعالة لتعزيز التفاهم الثقافي بين الشعوب من خلال ما تتيحه من فرص للاكتشاف والتبادل المعرفي، وهو ما يسهم في تعزيز قيم التسامح والاحترام المتبادل.<sup>[1]</sup>

كما أن زيادة الإقبال السياحي يُعد محفزًا لصون التراث الثقافي والبيئي من خلال دعم جهود الحفاظ على المواقع الأثرية والطبيعية. لكن رغم ما تقدمه السياحة من فوائد، يواجه السائح المعاصر تحديات متزايدة عند اتخاذ القرار السياحي، خاصة في ظل تنوع الخيارات وكثرة المعلومات المتاحة على الإنترنت، وتفاوت التكاليف، إلى جانب التأثير بالظروف المحلية والعالمية مثل الكوارث الطبيعية أو الاضطرابات الأمنية<sup>[2]</sup> هذه العوامل تجعل من اتخاذ القرار السياحي مهمة معقدة تتطلب أدوات مساعدة ذكية لتقديم دعم مخصص وفعال. وفي هذا السياق، تبرز أنظمة التوصية الذكية كحلول مبتكرة تساعد في تقليل تعقيد القرار السياحي عبر تقديم اقتراحات مخصصة بناءً على تفضيلات المستخدم وسلوكياته السابقة.<sup>[3]</sup>

تهدف هذه الدراسة إلى تطوير نظام توصية سياحي ذكي يراعي الأذواق الفردية للمستخدمين، ويعتمد على بيانات تقييمات الوجهات السياحية وتجارب الزوار، بما يُسهم في رفع جودة التجربة السياحية، وزيادة مستوى رضا السائحين، وتوجيههم إلى وجهات قد تكون غير معروفة، ولكنها تلبي تطلعاتهم.

من المتوقع أن يُسهم نظام التوصية الذكي في تحسين تجربة السائح من خلال تقديم توصيات مخصصة تسهم في اتخاذ قرارات أكثر دقة ورضا. كما يدعم توزيع الحركة السياحية بشكل أكثر توازنًا، مما يخفف الضغط عن الوجهات المزدحمة ويعزز الترويج لمواقع أقل شهرة. بالإضافة إلى ذلك، يوفر النظام بيانات قيّمة لتحليل سلوك السياح ودعم التخطيط السياحي المستقبلي.

## 2. الدراسات المرجعية Reference Study:

### 1. Tourism recommendation system based on semantic clustering and sentiment analysis<sup>[4]</sup>

في هذا البحث عالج الباحثون مشكلة وفرة المعالم السياحية وتعدد مصادر المعلومات المتاحة على الإنترنت ومنصات التواصل الاجتماعي، مما يُعقد اتخاذ القرار بشأن اختيار الوجهات السياحية. تم استخدام تعليقات المستخدمين كمصدر غني لاستخلاص التفضيلات من خلال تحليل المشاعر، إضافة إلى استخراج خصائص المعالم السياحية استنادًا إلى التقييمات النصية، ثم إجراء مطابقة بين تفضيلات المستخدم وخصائص المعالم لتقديم التوصيات. كما دمج النظام معلومات السياق (الوقت، الموقع، الطقس) لتحسين جودة النتائج. على الرغم من تميز هذه الدراسة في تحليل المحتوى النصي واستخدام العوامل السياقية، إلا أن نظام التوصية فيها يعتمد بشكل كامل على المحتوى النصي للمستخدمين، مما يجعله محدودًا عند غياب التعليقات أو وجود مستخدمين جدد (cold start). في المقابل، يعتمد النظام المقترح في هذه الدراسة على Matrix Factorization، وهي تقنية أكثر قوة ودقة في التوصية خاصة في حالات قلة البيانات النصية، مما يجعل التوصيات أكثر تخصيصًا ودقة.

### 2. Recommender Systems and Digital Storytelling to Enhance Tourism Experience in Cultural Heritage Sites.<sup>[5]</sup>

ركزت هذه الدراسة على تعزيز تجربة السائح في مواقع التراث الثقافي من خلال دمج تقنيات السرد الرقمي (Digital Storytelling) مع أنظمة التوصية. يقدم النظام مقترحات لمسارات ثقافية مخصصة بناءً على ملف تعريف المستخدم وتفضيلاته، مع تقديم محتوى وسائط متعددة لإثراء تجربة المستخدم.

تميزت هذه الدراسة بتركيزها على جودة المحتوى والتجربة السياحية أكثر من تركيزها على دقة الخوارزمية التوصية. كما أن التطبيق محصور إلى حد كبير في سياق المواقع الثقافية والتراثية. بالمقابل، يقدم النظام المقترح في هذا العمل توصيات دقيقة وقابلة للتخصيص لجميع أنواع السياح والوجهات السياحية، من خلال الجمع بين الخوارزميات الذكية والمعلومات الشخصية للمستخدم، مما يعزز قابلية التعميم.

### 3. A Personalized Tour Recommender in Python using Decision Tree. SSRN Electronic Journal<sup>[6]</sup>

في هذه الدراسة تم تطوير نظام توصية سياحي باستخدام لغة Python وإطار Django، حيث تم استخراج بيانات تقييمات العملاء من TripAdvisor باستخدام تقنيات الرحف، ثم تخزينها وتحليلها باستخدام شجرة القرار (Decision Tree). يقوم النظام بالتوصية بأماكن سياحية بناءً على مدخلات المستخدم (مثل الموقع والتقييمات)، دون الحاجة إلى بيانات سابقة من المستخدم نفسه.

رغم بساطة هذا النظام وسهولة تطبيقه، إلا أن استخدام Decision Tree في نظم التوصية يُعد محدودًا مقارنة بخوارزميات التعلم الآلي الأكثر تطورًا. لا تستطيع الأشجار التنبؤية التعامل بكفاءة مع تفاعلات المستخدمين المعقدة أو التوصيات الكامنة. في المقابل، يعتمد

النظام المقترح على خوارزمية Matrix Factorization التي تتميز بالدقة والقدرة على التعلم من الأنماط الخفية في التفاعلات بين المستخدمين والعناصر، مما يوفر توصيات أكثر فاعلية

4. Mobile recommender systems in tourism. Journal of Network and Computer Applications, 39, 319–333 [7]

في هذا البحث، استعرض الباحثون مجموعة من أنظمة التوصية السياحية المخصصة للهواتف المحمولة، والتي تعتمد في الغالب على الموقع الجغرافي والبيانات السياقية مثل الوقت والطقس لتقديم اقتراحات فورية للمستخدمين أثناء تنقلهم. وتركز الدراسة على تحليل الأنظمة التي تستخدم قواعد مخصصة أو فلاتر بسيطة لتوصية الأماكن السياحية بناءً على موقع المستخدم الحالي. على عكس بعض الأنظمة السابقة مثل ما قدمه Gavalas et al. (2014)، والتي اعتمدت على بيانات سياقية بسيطة مثل الموقع والوقت لتقديم التوصيات السياحية، فإن النظام المقترح في هذه الدراسة يدمج بين خوارزمية Matrix Factorization المتقدمة وخصائص المستخدم الشخصية مثل اللغة والعمر والاهتمامات. هذا الدمج يسمح بإنتاج توصيات مخصصة بدقة أعلى، حتى في حال غياب التفاعلات السابقة أو البيانات السياقية، وهو ما يجعل النظام المقترح أكثر قدرة على التكيف مع تنوع السياح واحتياجاتهم.

### 3. تصميم النظام System Design:

#### 3.1 المتطلبات الوظيفية للنظام:

يُصمم النظام ليقوم بعدة مهام رئيسية تشمل إدارة المستخدمين (إنشاء الحسابات وتحديث المعلومات الشخصية)، وجمع بيانات الرحلات السياحية وتفضيلات المستخدمين. يتيح النظام البحث عن الرحلات وعرض خيارات مشابهة، ويوفر توصيات مخصصة باستخدام تقنيتين رئيسيتين: التوصيات التقليدية المبنية على معايير مثل العمر والجنس، والتوصيات الذكية المعتمدة على خوارزميات الذكاء الاصطناعي لتحليل بيانات المستخدمين وتقديم اقتراحات دقيقة. كما يعرض النظام التوصيات بصور جذابة وتفصيل واضحة، ويدير قاعدة بيانات شاملة للوجهات والتقييمات والتكاليف، مع إتاحة تقييمات ومراجعات المستخدمين.

#### 3.2 المتطلبات غير الوظيفية:

يركز النظام على تقديم أداء عالي مع استجابة سريعة لضمان تجربة مستخدم سلسة، بالإضافة إلى حماية بيانات المستخدمين عبر تقنيات التشفير وأمان النظام. يضمن التصميم سهولة الاستخدام من خلال واجهات بديهية ومتوافقة مع مختلف الأجهزة، مع توفير الخدمة بشكل مستمر على مدار الساعة. كما يُصمم النظام ليكون قابلاً للصيانة والتطوير السريع، وقادراً على التوسع لاستيعاب عدد متزايد من المستخدمين وقاعدة بيانات أكبر.

#### 3.3 التقنيات والأدوات المستخدمة Techniques and Tools Used:

لتحقيق أهداف النظام المقترح، تم توظيف عدد من الأدوات البرمجية المتخصصة. حيث استُخدم ML.NET<sup>1</sup> لبناء نماذج التعلم الآلي، و Matrix Factorization Trainer<sup>2</sup> لتخصيص التوصيات بناءً على تفضيلات المستخدمين، بالإضافة إلى ASP.NET Core MVC<sup>3</sup> لتطوير واجهة الويب الخاصة بالنظام.

#### 3.4 الدراسة التحليلية للنظام Analytical Study of the System:

عندما يتعلق الأمر بالتخطيط لرحلة سياحية، يكون اختيار الوجهة السياحية من أكثر المهام تعقيداً بالنسبة للسائحين لكنها من بين المعلومات المتاحة على الإنترنت. وفي هذا السياق، لا يمكن إنكار أن تكنولوجيا المعلومات أصبحت جزءاً لا يتجزأ من مجال السياحة، حيث شهد هذا القطاع إقبلاً متزايداً في الفترة الأخيرة.<sup>[8]</sup> انسجاماً مع هذا التطور، تم تطوير نظام توصيات ذكي للسائحين وفق عدة مراحل. يمكن اختصارها وفق المراحل الأساسية لعملية التطوير:

##### 3.4.1 تعريف الاحتياجات:

يتطلب تطوير نظام توصيات ذكي للسائحين تحليلاً دقيقاً لاحتياجات المستخدمين والمشكلات التي يواجهونها في الوصول إلى الخدمات السياحية المناسبة. يهدف النظام المقترح إلى تزويد السائحين بتوصيات مخصصة تعتمد على تفضيلاتهم السابقة وتقييماتهم لأنشطة

1: ML.NET إطار مفتوح المصدر من Microsoft يُستخدم لتطوير نماذج تعلم الآلة باستخدام خوارزميات مثل التنقيب، التصنيف، والترشيح التعاوني.

2: Matrix Factorization Trainer أداة ضمن ML.NET تُطبق خوارزمية تفكيك المصفوفات لتقديم توصيات دقيقة وشخصية.

3: ASP.NET Core MVC إطار عمل حديث لبناء تطبيقات الويب بنمط Model-View-Controller، يتميز بالأداء العالي والمرونة في تطوير واجهات المستخدم.

ومعالم سياحية مختلفة، وذلك لتسهيل عملية اتخاذ القرار وتحسين تجربة السائح، كما يتطلب ذلك فهماً عميقاً لطبيعة الأنشطة والمعالم السياحية التي يفضلها المستخدمون، إلى جانب معرفة الخدمات الأكثر طلباً، مما يساعد على توجيه التوصيات بما يتناسب مع هذه التفضيلات والأنماط السلوكية.

### 3.4.2 جمع البيانات:

تم جمع البيانات اللازمة لتطوير نظام التوصية الذكي من خلال استبيان موجه شمل مجموعة من المحاور التي تعكس خصائص المستخدمين وتوجهاتهم نحو استخدام تقنيات الذكاء الاصطناعي في المجال السياحي. من خلال هذا الاستبيان، نسعى إلى فهم مدى رضا المستخدمين عن دقة وملاءمة الاقتراحات المقدمة من قبل الذكاء الاصطناعي، وكيفية تأثير هذه الاقتراحات على تجربتهم السياحية، والقدرة على تقديم خيارات مخصصة تلبي احتياجاتهم وتفضيلاتهم الشخصية.

بالإضافة إلى ذلك، يسعى الاستبيان إلى جمع آراء المستخدمين حول التحديات والمشكلات التي قد يواجهونها عند استخدام أنظمة التوصية التقليدية أو التوصية الذكية ومن خلال هذه المقارنة، نأمل في تسليط الضوء على الفوائد والعيوب المحتملة لكل منها مما يساعد في تحسين جودة الخدمات المقدمة وتلبية توقعات المستخدمين بشكل أفضل.

شمل معلومات عامة عن المشاركين مثل العمر والجنس ومستوى الخبرة التقنية، بالإضافة إلى تجربتهم مع خدمات الذكاء الاصطناعي في اقتراح الرحلات السياحية، ومستوى رضاهم والعوامل المؤثرة فيه مثل دقة الاقتراحات وسهولة الاستخدام. كما شمل الاستبيان مقارنة بين الذكاء الاصطناعي والأنظمة التقليدية من حيث الكفاءة والتفضيل المستقبلي. وُجّهت أسئلة مفتوحة للحصول على ملاحظات المستخدمين لتحسين الخدمة. ساعدت هذه البيانات في فهم احتياجات المستخدمين وتوجيه تصميم نظام التوصية الذكي.

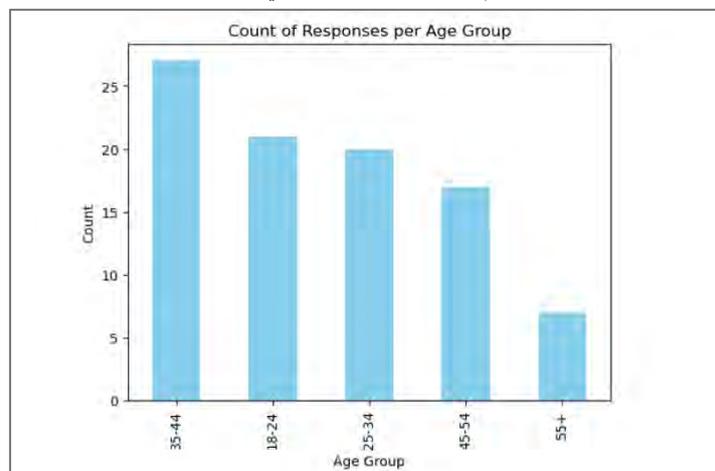
نتائج الاستبيان كانت كالتالي:

A	B	C	D	E	F	G	H	I	J	K	L	M	N	O	P
1	Age	Gender	Tech Expe	Used AI fo	Type of Tr	Satisfacto	Factors of	Best Aspe	Worst Asp	Used Trad	Comparisac	Key Differ	Preferred	Additional Notes	
2	25-34	Male	Intermedia	Yes	Internation	Satisfied	Speed; Ac	Customiza	Limited op	Yes	Slightly be	Speed; Co	AI	Improve diversity	
3	35-44	Female	Advanced	Yes	Domestic	Very Satis	Accuracy;	Ease of us	Lack of pe	Yes	Much bettr	Quality	AI	Add more filters	
4	18-24	Male	Beginner	No	-	-	-	-	-	Yes	No differer	Speed	Traditional	-	
5	45-54	Female	Intermedia	Yes	Both	Satisfied	Speed; Bu	Variety of	Complexity	Yes	Slightly wc	Complexity	Both	Simplify UI	
6	25-34	Male	Advanced	Yes	Internation	Very Satis	Customiza	Tailored si	Cost	Yes	Better	Quality	AI	Improve cost transparency	
7	35-44	Female	Beginner	No	-	-	-	-	-	No	-	-	AI	-	
8	18-24	Female	Intermedia	Yes	Domestic	Satisfied	Ease of us	Speed	Limited op	Yes	Slightly be	Cost; Ease	AI	More local options	
9	55+	Male	Beginner	No	-	-	-	-	-	Yes	No differer	Quality	Traditional	-	
10	25-34	Female	Advanced	Yes	Both	Very Satis	Speed; Ac	Real-time	Lack of su	Yes	Much bettr	Accuracy	AI	Enhance support	
11	35-44	Male	Intermedia	Yes	Internation	Satisfied	Quality; Cr	Ease of bc	Lack of pe	Yes	Slightly be	Cost; Spe	AI	Add personalization	
12	45-54	Female	Beginner	No	-	-	-	-	-	Yes	Slightly wc	Complexity	Traditional	-	
13	18-24	Male	Advanced	Yes	Domestic	Very Satis	Accuracy;	Tailored si	Complexity	Yes	Much bettr	Speed; Qu	AI	Simplify options	
14	25-34	Female	Intermedia	Yes	Internation	Satisfied	Budget; Qr	Customiza	Lack of div	Yes	Better	Quality	Both	Improve variety	
15	35-44	Male	Beginner	No	-	-	-	-	-	No	-	-	Traditional	-	
16	45-54	Female	Advanced	Yes	Both	Very Satis	Speed; Qu	Real-time	Cost	Yes	Better	Quality; S	AI	Improve affordability	
17	18-24	Female	Beginner	No	-	-	-	-	-	Yes	No differer	Cost	Traditional	-	
18	25-34	Male	Intermedia	Yes	Domestic	Satisfied	Customiza	Ease of bc	Limited op	Yes	Slightly be	Quality	AI	Add more destinations	
19	35-44	Female	Advanced	Yes	Internation	Very Satis	Accuracy;	Tailored si	Lack of su	Yes	Much bettr	Speed; Qu	AI	Enhance support	
20	45-54	Male	Intermedia	Yes	Both	Satisfied	Cost; Qual	Ease of us	Complexity	Yes	Slightly be	Ease of us	Both	Simplify process	
21	55+	Female	Beginner	No	-	-	-	-	-	Yes	No differer	Complexity	Traditional	-	
22	25-34	Male	Advanced	Yes	Internation	Very Satis	Speed; Ac	Customiza	Cost	Yes	Much bettr	Quality; S	AI	Improve affordability	
23	18-24	Female	Intermedia	Yes	Domestic	Satisfied	Speed; Co	Ease of bc	Limited op	Yes	Slightly be	Speed; Co	AI	Add more filters	
24	35-44	Male	Beginner	No	-	-	-	-	-	Yes	No differer	Ease of us	Traditional	-	
25	45-54	Female	Advanced	Yes	Internation	Satisfied	Accuracy;	Tailored si	Complexity	Yes	Better	Quality; S	AI	Simplify options	
26	18-24	Male	Intermedia	No	-	-	-	-	-	Yes	Slightly wc	Speed	Traditional	-	
27	25-34	Female	Advanced	Yes	Domestic	Very Satis	Speed; Qu	Real-time	Lack of su	Yes	Much bettr	Quality	AI	Enhance support	
28	35-44	Male	Intermedia	Yes	Both	Satisfied	Budget; Qr	Ease of us	Complexity	Yes	Better	Cost	Both	Improve cost transparency	

شكل 1: نتائج الاستبيان

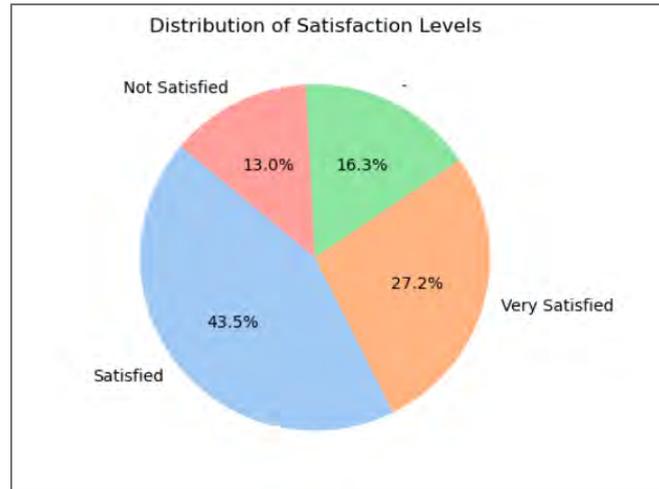
### 3.4.3 تحليل البيانات:

أظهرت نتائج تحليل البيانات أن الفئة العمرية بين 35 و44 عاماً كانت الأكثر تجاوباً، تليها الفئة 18-24 عاماً، مما يشير إلى اهتمام هذه الفئات بالتكنولوجيا وأكثر انفتاحاً وقبولاً لاستخدام أدوات الذكاء الاصطناعي.

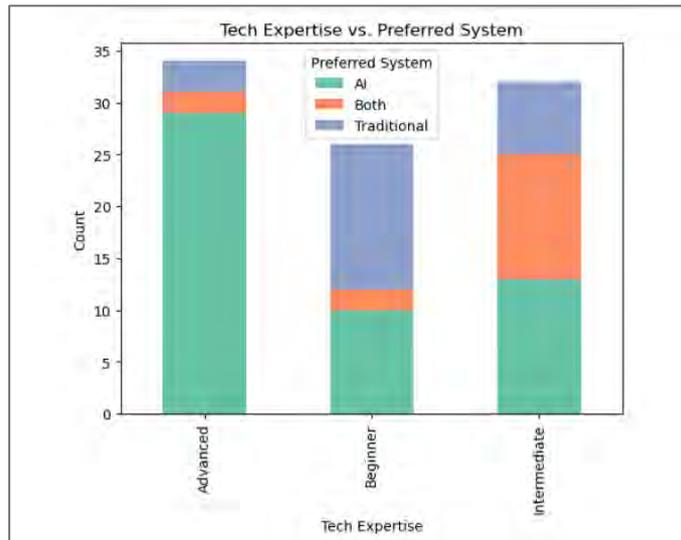


شكل 2: التحليل البياني لكل مجموعة عمرية

كما أظهرت نتائج الاستبيان أن معظم المشاركين عبّروا عن مستوى رضا مرتفع أو متوسط عن تجربة استخدام النظام الذكي، مما يدل على تقبل عام إيجابي للفكرة. مع ذلك، وُجدت نسبة قليلة غير راضية، ما يشير إلى وجود فرصة لتحسينات مستقبلية.



شكل 3: التحليل البياني لمدى رضا الأفراد عن تجربة استخدام الذكاء الاصطناعي لاقتراح الرحلات وفيما يخص النظام المفضل للاستخدام، أظهرت النتائج أن غالبية المشاركين يفضلون نظام التوصية الذكي (AI)، لا سيما ذوي الخبرة التقنية المتقدمة، في حين فضّل بعض المستخدمين المبتدئين الأنظمة التقليدية.



شكل 4: تحليل البياني لعدد الاستجابات لكل نظام مفضل

للاطلاع على التفاصيل البرمجية الكاملة المستخدمة في تحليل البيانات، يُرجى مراجعة الملحق (أ).

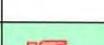
#### النتيجة:

أظهرت التحليلات أن هناك علاقة واضحة بين الفئة العمرية والخبرة التقنية للأفراد وبين تفضيلاتهم ودرجة رضاهم عن تجربة الذكاء الاصطناعي. بشكل عام، سجلت النتائج مستوى رضا مرتفعاً إلى متوسط لدى معظم المشاركين، مع تفضيل واضح لنظام معين (نظم التوصية السياحية الذكية)، خاصة بين ذوي الخبرة التقنية المتقدمة. ومع ذلك، لوحظ تفاوت في مستويات الرضا بين الفئات العمرية، حيث أبدت بعض الفئات استجابة أقل إيجابية.

بناءً على ذلك، يُوصى بالعمل على تحسين تجربة المستخدم لتتناسب مع احتياجات الفئات العمرية الأقل رصاً، مع تعزيز مميزات النظام المفضل (نظم التوصية السياحية الذكية) لضمان استمرار جاذبيته، مع مراعاة سهولة الاستخدام للمبتدئين. كما يُفضل إجراء دراسات إضافية لفهم العوامل المؤثرة في تفضيلات المستخدمين بشكل أعمق، مما يساهم في تطوير حلول أكثر دقة وفعالية تُلبّي توقعات مختلف الفئات المستهدفة.

## 3.4.4 تصميم النموذج:

تم تصميم نموذج نظام التوصية الذكية باستخدام تقنية التصفية التعاونية من خلال جمع معلومات عن التفضيلات أو الذوق للعديد من المستخدمين ومن ثم التنبؤ باهتمامات المستخدم. بمعنى أنه إذا أعجبنا أنا وأنت بالعديد من نفس الوجهات السياحية، فربما أحب مناطق سياحية أخرى تحبها.

شكل 5: التصفية التعاونية

في الشكل 5، نرى أشخاصاً يصنفون وجهات سياحية مختلفة وهي النقطة الأساسية لهذا النهج حيث نحتاج دائماً إلى مقياس أداء يسمى التقييم. بعد ذلك، يقوم النظام بالتنبؤ بتقييم المستخدم لعنصر ما، والذي لم يصنفه المستخدم بعد مع مراعاة عناصر أو مستخدمين مشاهيرين.

يعتمد نظام التوصية المستخدم في هذا البحث على تقنية التصفية التعاونية (Collaborative Filtering) من خلال خوارزمية تفكيك المصفوفات (Matrix Factorization)، وهي من أكثر الأساليب فعالية في هذا المجال. يتم تمثيل العلاقة بين المستخدمين والرحلات السياحية في مصفوفة تفاعلية ذات الأبعاد  $(m \times n)$  حيث تمثل الصفوف  $(m)$  المستخدمين، بينما تمثل الأعمدة  $(n)$  العناصر مثل الرحلات السياحية، مع وجود العديد من القيم المفقودة نتيجة عدم تفاعل جميع المستخدمين مع كل العناصر.

لحل هذه المشكلة، يتم تفكيك المصفوفة إلى مصفوفتين من العوامل الكامنة: الأولى تمثل المستخدمين والثانية تمثل الرحلات. ومن خلال ضرب هاتين المصفوفتين، يمكن تقدير القيم المفقودة بطريقة تعكس الأنماط الكامنة في التفاعل. لتقييم جودة التقدير، تُستخدم دالة الخسارة التي تقيس الفرق بين القيم الحقيقية والمتوقعة. ويُعتمد في ذلك على دالة الخطأ التربيعي المتوسط (Mean Squared Error - MSE) مع إضافة معامل تنظيم (Regularization Term) يقلل من الإفراط في التكيف ويحسن من استقرار النموذج. يتم تحسين النموذج عبر تقنية التحسين التدرجي العشوائي (Stochastic Gradient Descent - SGD)، حيث تُحدَّث القيم تدريجياً بناءً على الخطأ، ما يؤدي إلى تحسين التوقعات وتقليل دالة الخسارة مع تكرار العملية. يتم تكرار هذه العملية لعدة مرات (مثلاً 20 مرة كما في الكود المستخدم) حيث تنخفض قيمة  $R$  وتتحسن التنبؤات، مما يجعل النظام قادراً على تقدير القيم المفقودة بدقة أكبر في مصفوفة التفاعل  $R$ . نلاحظ أن القيم المتوقعة تقترب كثيراً من القيم الأصلية، مما يدل على أن النموذج نجح في تعلم الأنماط الكامنة بين المستخدمين والعناصر.

ويُظهر النموذج دقة عالية عند استخدام كمية بيانات كافية وضبط جيد للمعاملات، مما يجعله خياراً شائعاً في أنظمة التوصية. ملاحظة: تم تضمين المعادلات والتفاصيل التقنية الخاصة بدالة الخسارة والتدريب في الملحق (ت). لبناء النموذج برمجياً، تم استخدام مكتبة ML.NET التي توفر أدوات فعالة لإنشاء نماذج تعلم آلي باستخدام خوارزمية Matrix Factorization

Factorization

يمكن الرجوع إلى الفقرة 4.2، لمزيد من التفاصيل حول تصميم النموذج، بناء النظام الذكي، والمعادلات التقنية.

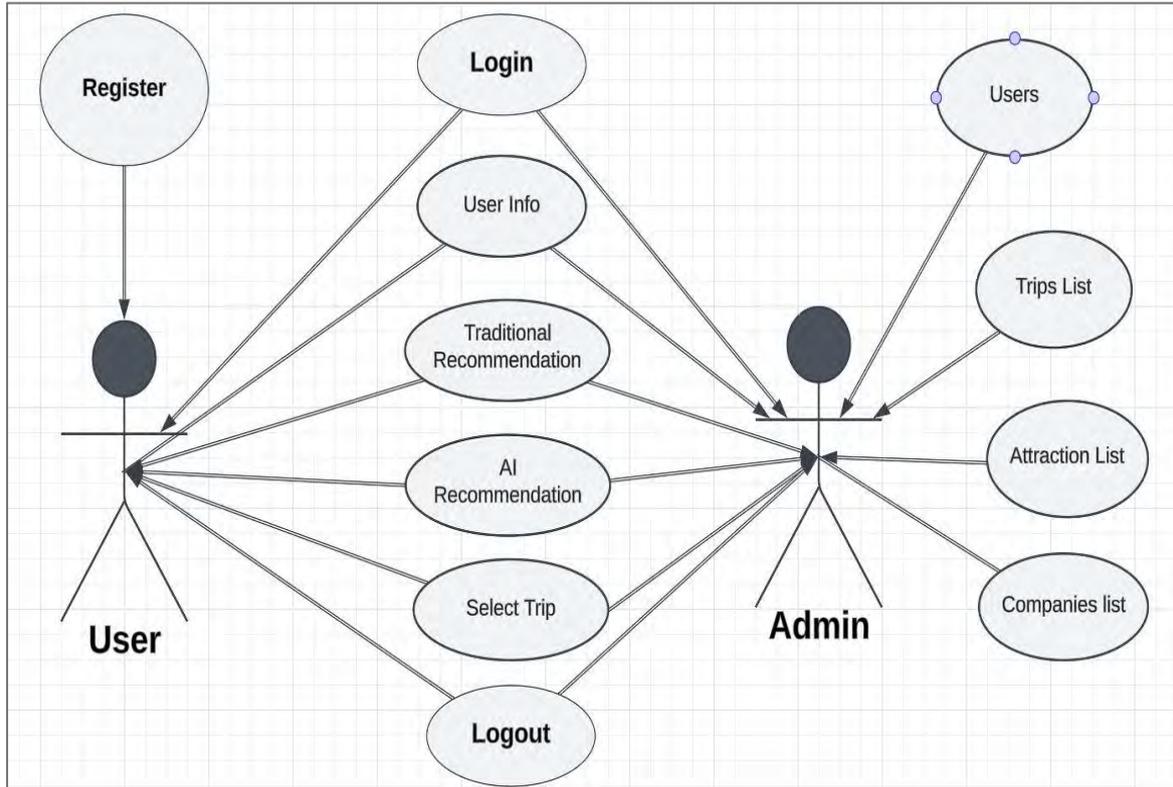
## 3.4.5 بناء وتصميم قاعدة البيانات Building and Designing the Database:

تم اعتماد قاعدة بيانات SQL Server. يتميز بالعديد من الميزات مثل الأداء العالي، الأمان القوي، التوافر العالي واستعادة البيانات، قابلية التوسع، إدارة البيانات الضخمة، التكامل مع التطبيقات والخدمات الأخرى.

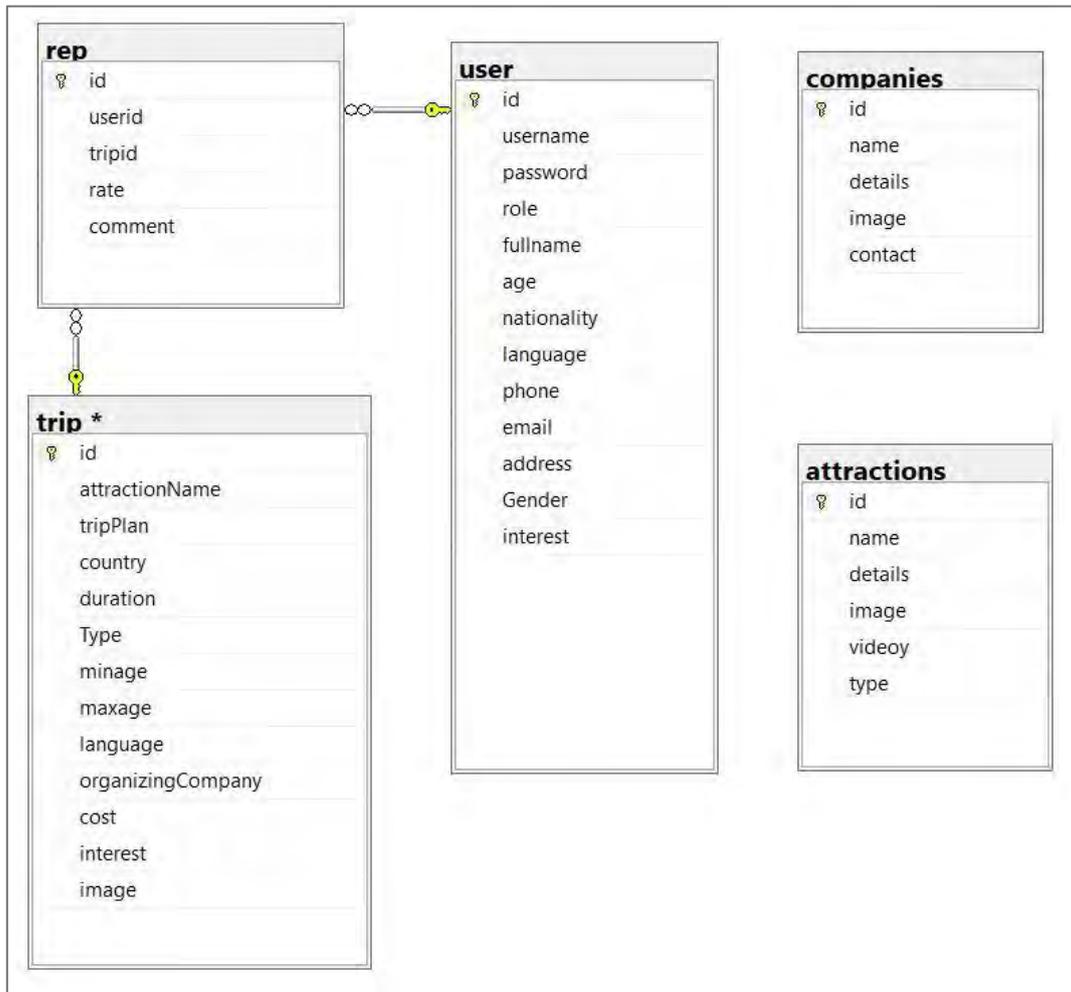
جدول 1: الجداول المستخدمة في قاعدة البيانات

اسم الجدول	الوصف
Users	يحتوي على بيانات المستخدمين مثل: الاسم، العمر، الايميل، كلمة المرور، الدور، نوع السياحة المفضلة..
Attractions	يحتوي على معالم الجذب والمعلومات الخاصة بها مثل تفاصيل المعلم والصور والفيديو.
Trips	يحتوي على قائمة الرحلات المنشئة مثل الشركة المنظمة للرحلة ومعلم الجذب المختار للرحلة والتكلفة وغيرها..
Companies	يحتوي على قائمة الشركات المنظمة للرحلات وتفاصيل كل شركة.
Rep	يحتوي على قائمة التقييمات للرحلات من قبل المستخدمين.

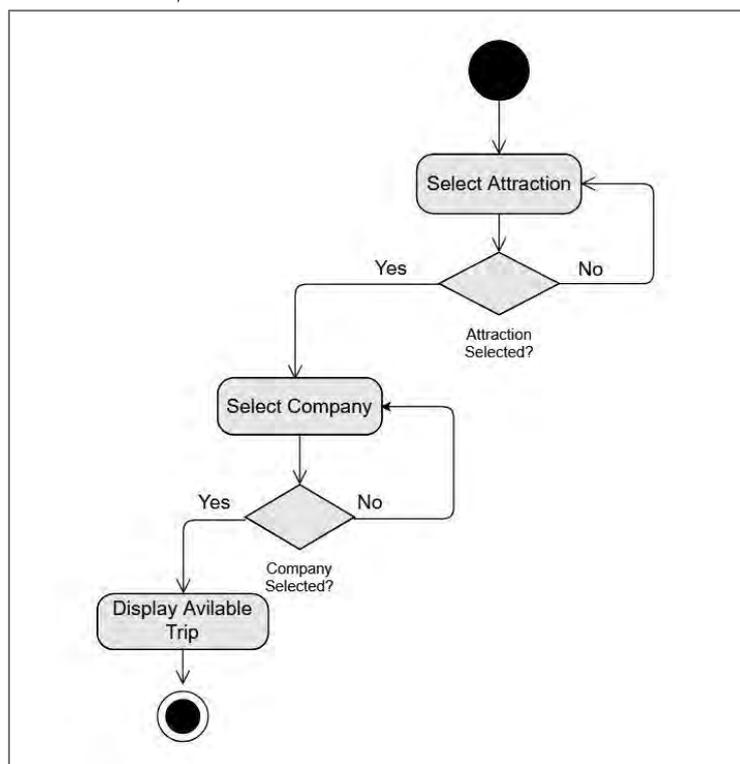
3.4.6 مخططات النظام System Diagrams:



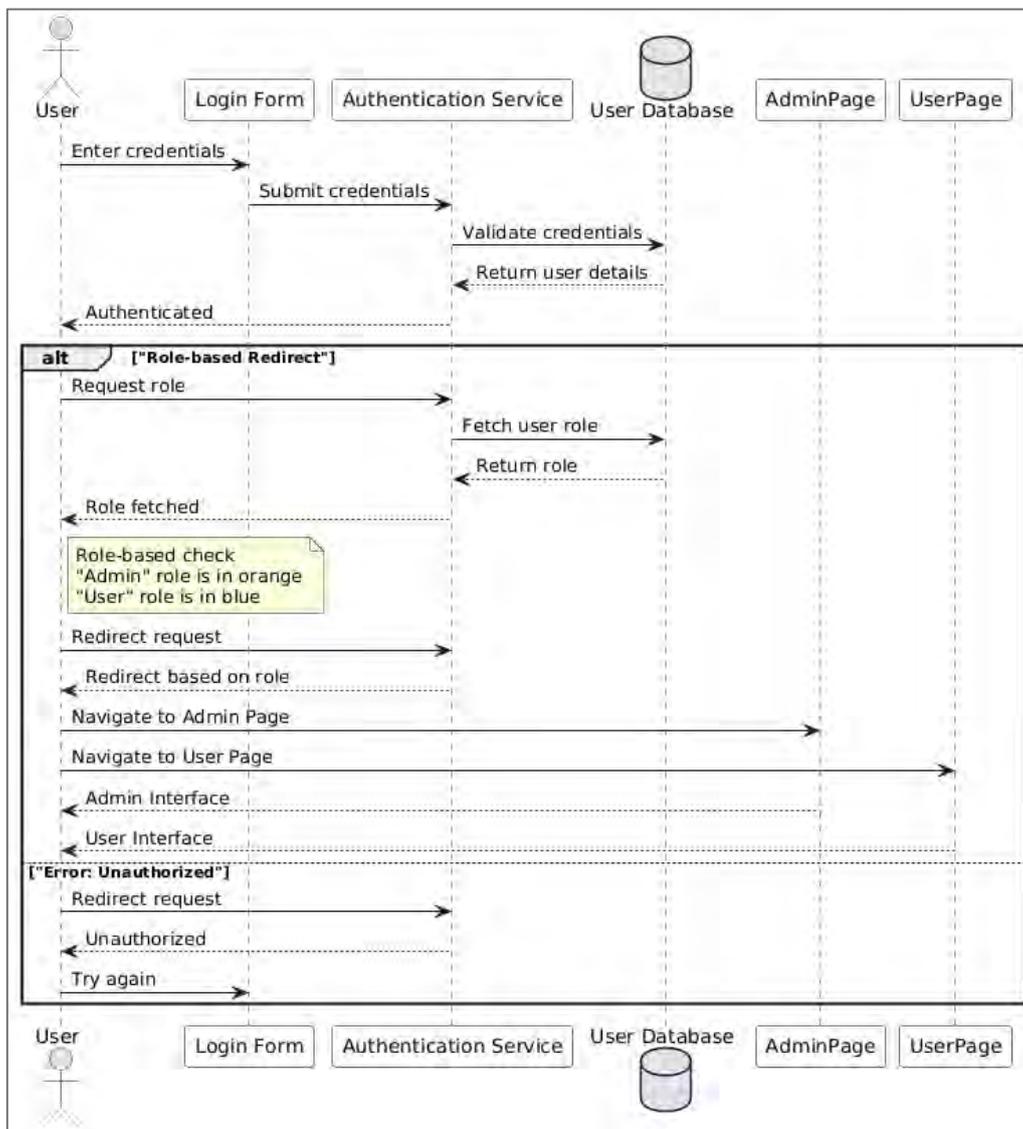
شكل 6: مخطط ERD Diagram لقاعدة البيانات



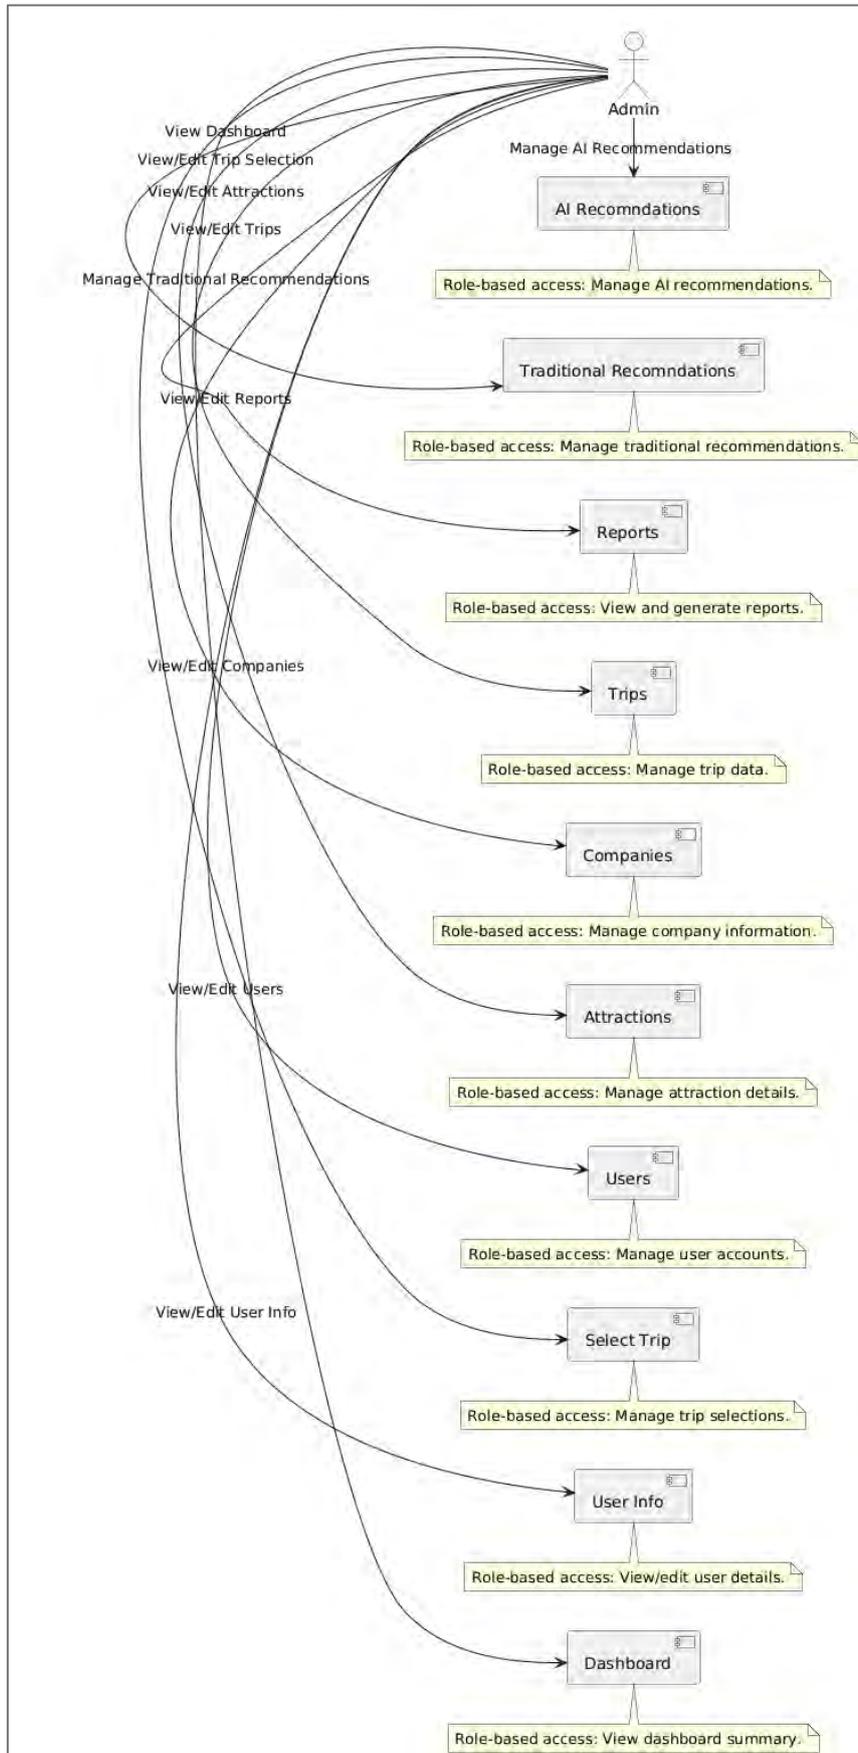
شكل 7: مخطط Use Case Diagram للنظام



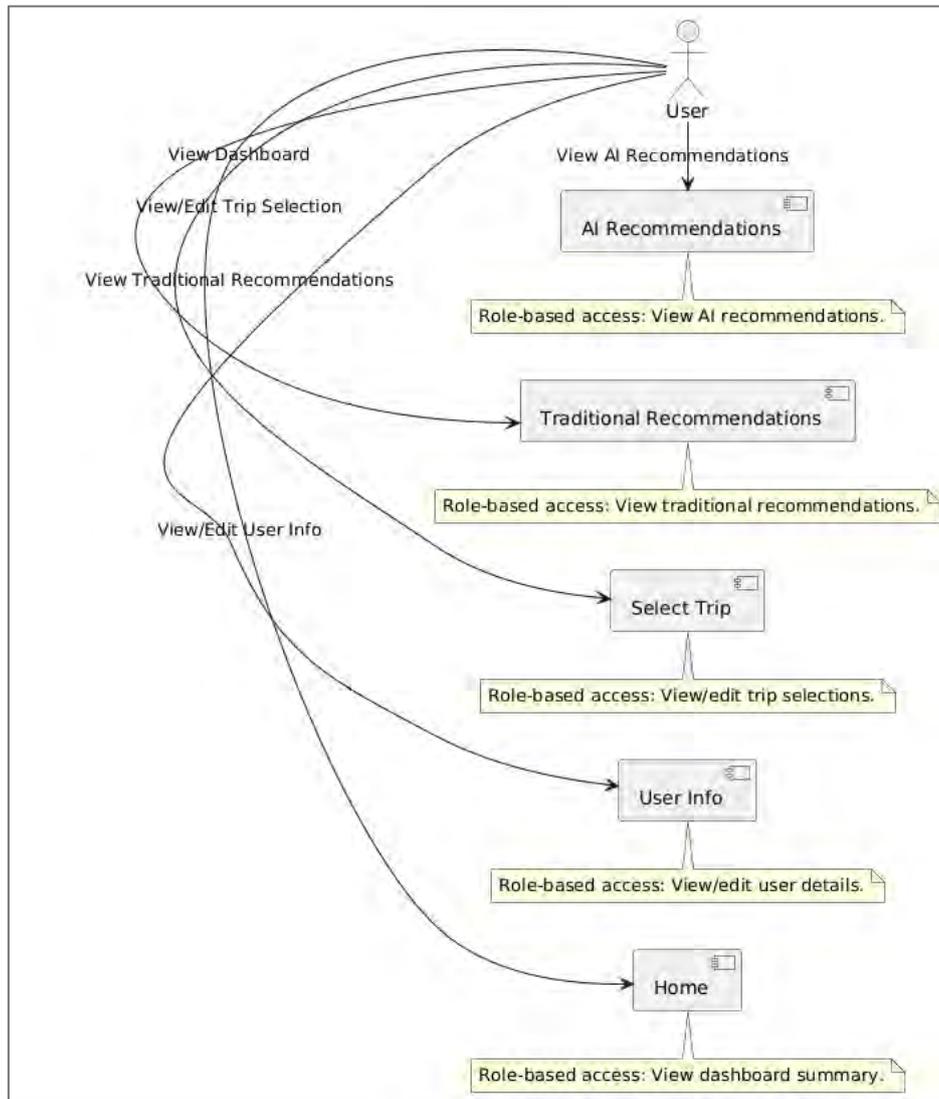
شكل 8: مخطط Activity Diagram توضيحي لصفحة المساعدة باختيار الرحلة المناسبة



شكل 9: مخطط sequence Diagram توضيحي لعمليات تسجيل الدخول



شكل 10: مخطط توضيحي لعرض صلاحيات المدير



شكل 11: مخطط توضيحي لعرض صلاحيات المستخدم

#### 4. تنفيذ النظام:

##### 4.1 بناء نظام التوصية التقليدية Building a Traditional Recommendation System:

لبناء نظام توصية تقليدي سيتم الاعتماد على تقنية التصنيف القائمة على المحتوى، حيث يتم تقديم التوصيات للمستخدمين من خلال بيانات المستخدم الفردي فقط. يلعب وصف العنصر و ملف تعريف المستخدم المعين دورًا مهمًا في تقنية التصنيف القائمة على المحتوى. وفيما يلي المفهوم الأساسي لأنظمة التوصية القائمة على المحتوى.

أولاً، تحليل وصف العناصر التي يفضلها مستخدم فردي معين لتحديد التفضيلات التي يمكن استخدامها لوصف هذه العناصر. يتم تخزين هذه التفضيلات في ملف تعريف المستخدم. ثانياً، مقارنة سمات كل عنصر بملف تعريف المستخدم بحيث يتم التوصية فقط بالعناصر ذات الصلة التي لها درجة عالية من التشابه مع ملف تعريف المستخدم لهذا المستخدم المعين.<sup>[9]</sup>

تظهر التوصيات وفق الأنظمة والبيئة العمل التقليدية:

1- التفضيلات حسب اهتمام المستخدم لنوع الرحلة:

حيث يتم اختيار الرحلات حسب تفضيل المستخدم لنوع الرحلة (ثقافية، تعليمية، مغامرة..).

2- التفضيلات حسب العمر:

حيث تظهر الرحلات الموافقة لأعلى التقييمات للمستخدمين من نفس عمر المستخدم الحالي

3- التفضيلات حسب اللغة:

حيث تظهر الرحلات الموافقة لأعلى التقييمات للمستخدمين من نفس لغة المستخدم الحالي

4- التفضيل الأساسي:

حيث تظهر الرحلات الموافقة للتقييمات السابقة مجتمعة

- يُشار إلى أن الكود التفصيلي والعمليات التقنية المرتبطة بهذه الخطوات متوفرة بالكامل في الملحق التقني (ب).

#### 4.2 بناء نموذج التدريب لنظام التوصية الذكية برمجيًا:

تم تنفيذ نظام التوصية الذكية باستخدام بيئة تطوير ASP.NET Core لتوفير واجهة مستخدم تفاعلية، مع الاعتماد على مكتبة ML.NET لبناء نموذج تعلم آلي يستخدم خوارزمية Matrix Factorization للتصفية التعاونية. يركز هذا التنفيذ على دمج النموذج التدريبي داخل التطبيق بحيث يمكن التنبؤ بتفضيلات المستخدمين في الوقت الفعلي، وربط واجهة المستخدم مع قاعدة البيانات لتخزين واسترجاع بيانات التقييمات والرحلات السياحية.

يتضمن بناء نموذج التدريب عدة خطوات رئيسية تبدأ باستدعاء المكتبات الأساسية من مكتبة ML.NET مثل Microsoft.ML و Microsoft.ML.Data و Microsoft.ML.Trainers بعد ذلك، يتم إنشاء فئة (class) باسم RepData لتخزين بيانات التدريب، حيث تعكس خصائصها أعمدة جدول Rep المصدر للبيانات.

ثم تُستخدم دالة LoadDataAsync لجلب البيانات من قاعدة البيانات وتحويل السجلات إلى كائنات من نوع RepData، بالإضافة إلى إعداد خط معالجة (pipeline) يتضمن تحويل القيم باستخدام MapValueToKey لتحويل مدخلات المستخدم و Userid والرحلة Tripid إلى مفاتيح رقمية موحدة، مما يسهل على النموذج فهم العلاقات بين المستخدمين والعناصر بشكل أفضل.

يُعدّ النموذج باستخدام خوارزمية Matrix Factorization التي تعتمد على عدة معلمات أساسية:

- LabelColumnName: لتحديد عمود التقييمات (Rate)

- MatrixColumnIndexColumnName: لتحديد عمود معرف المستخدم (Userid)

- MatrixRowIndexColumnName: لتحديد عمود معرف الرحلة (Tripid)

- NumberOfIterations: عدد التكرارات لتدريب النموذج (20 تكرارًا)

- ApproximationRank: وهو عدد العوامل الكامنة في المصفوفة (100)

بعد إعداد الخط، يتم تدريب النموذج عبر دالة Fit على البيانات المحملة، ثم يُنشأ محرك التنبؤ (PredictionEngine) لاستخدام النموذج في توقع تقييمات المستخدم لرحلات جديدة عن طريق تقديم معرف المستخدم ومعرف الرحلة كمدخلات، حيث تعيد الدالة Predict القيمة المتوقعة للتقييم.

يُشار إلى أن الكود التفصيلي والعمليات التقنية المرتبطة بهذه الخطوات متوفرة بالكامل في الملحق التقني (ب).

#### 4.3 استخدام نموذج التدريب المنشأ للتنبؤ بتقييم المستخدم على الرحلات:

توضح الفقرة كيفية استخدام نموذج التعلم الآلي المُدرَّب لإجراء توقعات تقييمات المستخدمين للرحلات بهدف تقديم توصيات مخصصة. يبدأ التنفيذ بالتأكد من أن النموذج قد تم تدريبه بالفعل من خلال استدعاء الدالة (InitializeModelAsync)، التي تتولى تحميل البيانات وبناء النموذج وتدريبه إذا لم يكن جاهزًا مسبقًا. بعدها، يتم جلب جميع الرحلات المخزنة في جدول Trips من قاعدة البيانات باستخدام Entity Framework Core، وتحويل النتائج إلى قائمة باستخدام (ToListAsync)

معرفة معرف المستخدم الحالي تُستخدم لتوليد التوقعات حيث يتم التكرار على كل رحلة في القائمة، ويُطبق النموذج المدرب لتقدير تقييم المستخدم للرحلة باستخدام معرف المستخدم (Userid) ومعرف الرحلة (Tripid) إذا تم العثور على تفاصيل الرحلة المطابقة، تُضاف التوصية لقائمة النتائج التي تشمل معرف الرحلة، واسمها، وصورة عنها، بالإضافة إلى التقييم المتوقع. بعد الانتهاء من التكرار، يتم ترتيب قائمة التوصيات ترتيبًا تنازليًا بناءً على قيمة التقييم المتوقع لضمان عرض أفضل الرحلات أولًا.

المعلومات الرئيسية التي يؤثر بها النموذج على جودة ودقة التوصيات تشمل:

- عدد التكرارات (NumberOfIterations): حيث يتم تدريب النموذج على مدى 20 دورة، ما يساعد في تحسين دقة التوقعات تدريجيًا.

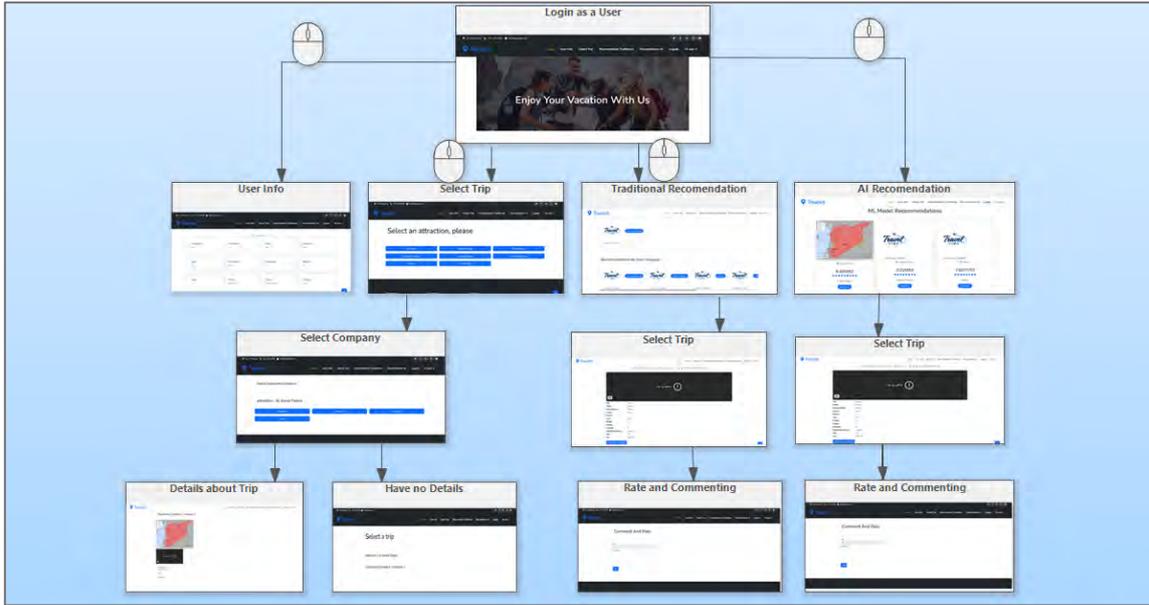
- رتبة تقريب المصفوفة (ApproximationRank): تم تعيينها إلى 100، وتمثل عدد العوامل الكامنة التي تفكك المصفوفة الأصلية إلى مصفوفتين لتقدير القيم المفقودة بين المستخدمين والعناصر.

- أعمدة المؤشرات: حيث يتم تحديد Userid كمؤشر للمستخدم و Tripid كمؤشر للرحلة، لتسهيل التعامل مع بيانات التفاعلات بشكل منظم داخل الخوارزمية.
- عمود التقييم (Rate): هو القيمة المستهدفة التي يحاول النموذج التنبؤ بها، وهي تقييم المستخدم للرحلة. تُخزن النتائج في ViewBag ليتم تمريرها إلى واجهة المستخدم وعرضها بطريقة منظمة وجذابة. يُشار إلى أن الكود التفصيلي والعمليات التقنية المرتبطة بهذه الخطوات متوفرة بالكامل في الملحق التقني (ب).

#### 4.4 مخطط شاشات النظام System Screenflow Diagram:

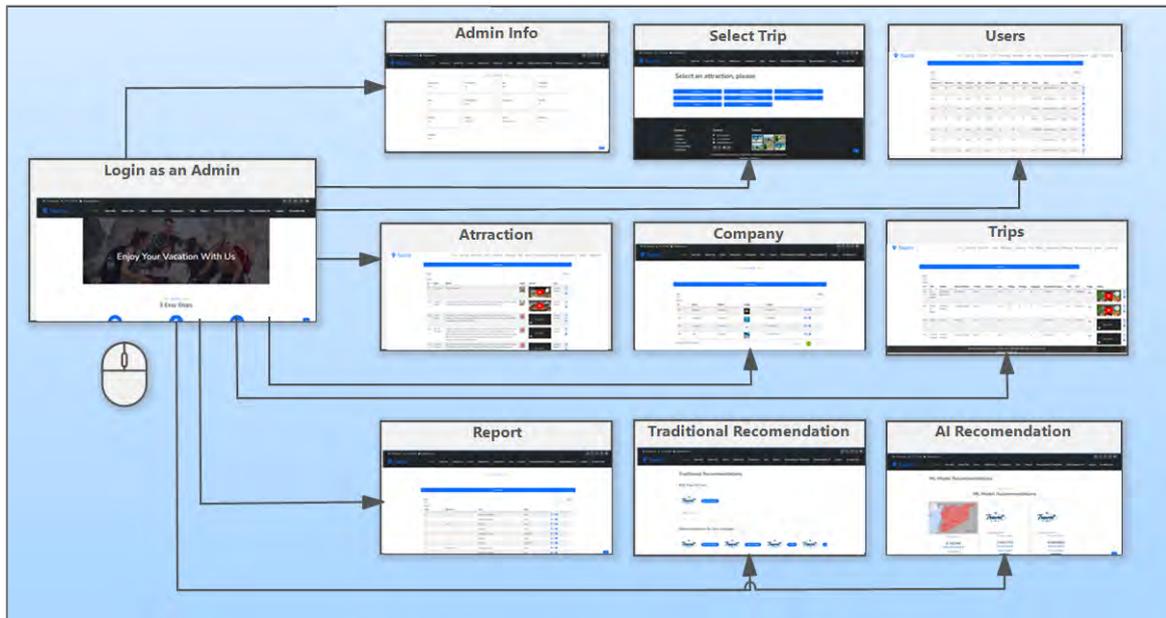
الصفحة الرئيسية هي صفحة ترحيب بزوار الموقع واستعراض لأراء العملاء السابقين ويتم توجيه المستخدم لتسجيل حساب جديد او تسجيل الدخول بحال وجود حساب سابقاً.

1. عند تسجيل الدخول كـ User:



شكل 12: مخطط الشاشات للموقع عند تسجيل الدخول كمستخدم عادي

2. عند تسجيل الدخول كـ Admin:



شكل 13: مخطط الشاشات للموقع عند تسجيل الدخول كمدير

## 4.5 صفحات الموقع Website Pages:

يتضمن النظام واجهات تفاعلية لكل من المستخدم والمدير، صُممت لتقديم تجربة مبسطة وسلسة في استعراض الرحلات السياحية والحصول على التوصيات المناسبة.

عند تسجيل الدخول كمستخدم عادي يكون من صلاحياته الدخول إلى الصفحات التالية:

- User Info: تظهر المعلومات الشخصية للمستخدم
- Select Trip: لاختيار رحلة بشكل يدوي.
- Traditional Recommendation: لاقتراح رحلة بناءً على نظم التوصية التقليدية.
- AI Recommendation: لاقتراح رحلة بناءً على نموذج الذكاء الاصطناعي.



شكل 14: واجهة الموقع عند تسجيل الدخول كمستخدم

## قسم المدير:

واجهة المدير توفر صلاحيات متقدمة تشمل إدارة المستخدمين، الشركات، المعالم، والرحلات، مما يدعم التحكم الكامل في محتوى النظام.

عند تسجيل الدخول كمدير موقع يكون من صلاحياته الدخول إلى الصفحات التالية:

- User Info: تظهر المعلومات الشخصية للمستخدم
  - Select Trip: لاختيار رحلة بشكل يدوي.
  - Traditional Recommendation: لاقتراح رحلة بناءً على نظم التوصية التقليدية.
  - AI Recommendation: لاقتراح رحلة بناءً على نموذج الذكاء الاصطناعي.
  - Users: قائمة المستخدمين الموجودين في النظام.
  - Attractions: قائمة بمعالم الجذب السياحية.
  - Companies: قائمة بتفاصيل جميع الشركات المسجلة بالنظام.
  - Trips: قائمة الرحلات المنظمة من قبل الشركات المسجلة في النظام.
- للاطلاع على كافة الصفحات والواجهات التفصيلية الأخرى، يرجى مراجعة الملحق (ث)

## 5. النتائج والتوصيات

يتميز نظام التوصية المعتمد على تحليل المصفوفات بقدرته على اكتشاف الأنماط الخفية في تفضيلات المستخدمين والتكيف مع تغيرها، فضلاً عن مرونته في التعامل مع البيانات الناقصة ودقته العالية في التخصيص، مما يجعله أكثر فعالية من الأنظمة التقليدية المعتمدة على البيانات الديموغرافية. ومع ذلك، تظل الأنظمة التقليدية خياراً مناسباً في الحالات التي تتطلب بساطة التنفيذ وقابلية التفسير وانخفاض التكاليف.

## جدول 2: مقارنة بين نظامي التوصية التقليدي والمعتمد على الذكاء الاصطناعي

الميزة	النظام التقليدي	النظام الذكي
دقة التوصيات	متوسطة	عالي
التعامل مع البيانات الكبيرة	محدود	ممتاز
التخصيص الشخصي	محدود	عالي
التعامل مع البيانات المفقودة	ضعيف	عالي
سهولة التنفيذ	عالي	متوسطة
تفسير النتائج	عالي	متوسطة
التكلفة	منخفضة	مرتفعة

## 5.1 النتائج Results:

أظهرت نتائج النظام المقترح فعالية ملحوظة في عدة جوانب تتعلق بجودة التوصيات ورضا المستخدمين. فقد ساهم اعتماد تقنيات الذكاء الاصطناعي (ML.NET) في تحسين دقة التوصيات المقدمة، حيث تحقق توافق أعلى بين تفضيلات المستخدمين والوجهات السياحية المقترحة مقارنة بأنماط التوصية التقليدية. كما انعكس هذا التحسن على مستوى رضا المستخدمين، إذ أبدى عدد كبير منهم ارتياحاً واضحاً لجودة التوصيات وملاءمتها لاحتياجاتهم واهتماماتهم الشخصية، وهو ما يُعزى إلى تحليل البيانات والسلوكيات الفردية بشكل دقيق. علاوة على ذلك، وفر النظام باقة متنوعة من الوجهات السياحية، مما أتاح تلبية تطلعات مستخدمين من خلفيات وميول مختلفة. وقد كان لنظام التقييم الرقمي دور فعال في دعم عملية اتخاذ القرار، حيث أظهر المستخدمون اعتماداً كبيراً على تقييمات الوجهات عند المقارنة بين البدائل السياحية المتاحة.

## 5.2 الخلاصة Conclusion:

يعالج هذا البحث إحدى المشكلات الرئيسية في قطاع السياحة، ويقترح حلاً تقنياً يعتمد على الذكاء الاصطناعي لتقديم توصيات سياحية مخصصة. أثبت النظام فعاليته في تحسين تجربة المسافر، وزيادة كفاءة التوصيات، ويمثل خطوة واعدة نحو تعزيز السياحة الرقمية وتطوير الخدمات السياحية الذكية.

## 5.3 التوصيات Recommendations:

يوصى بتعزيز دمج تقنيات الذكاء الاصطناعي والتعلم الآلي في تطوير نظم التوصية السياحية، لما توفره من دقة أعلى وقدرة على تخصيص المحتوى وفقاً لتفضيلات المستخدمين الفردية. كما يُستحسن توسيع قاعدة البيانات المعتمدة في النظام لتشمل معلومات أكثر تنوعاً وتفصيلاً عن الوجهات السياحية وسلوك المستخدمين، بهدف تحسين جودة التوصيات وتوسيع نطاق الخيارات المتاحة. ويُقترح ربط النظام بمنصات التواصل الاجتماعي للاستفادة من البيانات السلوكية والتفضيلية المتاحة، بما يساهم في تقديم توصيات أكثر مواءمة للسياق الشخصي. كذلك، ينبغي تطوير واجهة المستخدم لتكون أكثر تفاعلية وسهولة، بما يعزز من تجربة الاستخدام ويزيد من معدل التفاعل مع النظام. كما يُوصى بإجراء تقييم دوري لأداء النظام من خلال تحليل ملاحظات المستخدمين ومؤشرات الأداء، بما يتيح التحسين المستمر وتفاذي أوجه القصور. وأخيراً، يُقترح تطوير آلية ديناميكية لتقديم توصيات فورية في الوقت الفعلي، اعتماداً على التغيرات اللحظية في سلوك المستخدم واهتماماته، مما يعزز من مرونة النظام وكفاءته التفاعلية.

## المراجع المستخدمة References

- 1- Richards, G. (2018). Cultural tourism: A review of recent research and trends. *Journal of Hospitality and Tourism Management*, 36, 12–21.
- 2- Werthner, H., & Ricci, F. (2004). E-commerce and tourism. *Communications of the ACM*, 47(12), 101–105.
- 3- Ricci, F., Rokach, L., & Shapira, B. (2015). *Recommender systems handbook*. Springer.
- 4- Abbasi-Moud Z, Vahdat-Nejad H, Sadri J. Tourism recommendation system based on semantic clustering and sentiment analysis. *Expert Systems with Applications*. 2021 Apr;167:114324.

- 5- Casillo M, Massimo De Santo, Lombardi M, Mosca R, Santaniello D, Valentino C. Recommender Systems And Digital Storytelling To Enhance Tourism Experience In Cultural Heritage Sites. 2021 Aug
- 6- Khan, N., & Haroon, M. (2023). A Personalized Tour Recommender in Python using Decision Tree (June 15, 2023). *SSRN Electronic Journal*
- 7- Gavalas, D., Konstantopoulos, C., Mastakas, K., & Pantziou, G. (2014). Mobile recommender systems in tourism. *Journal of Network and Computer Applications*, 39, 319–333
- 8- Thiengburanathum, P., Cang, S., & Yu, H. (2015). A decision tree based recommendation system for tourists. *2015 21st International Conference on Automation and Computing (ICAC)*.
- 9- Patel B, Desai P, Panchal U. Methods of recommender system: A review. 2017 International Conference on Innovations in Information, Embedded and Communication Systems (ICIIECS). 2017 Mar;
- 10- Angélica González-Sánchez, Monge-Martínez J, Ballesteros-López L, Armas-Arias S. Logistic Regression Model and Decision Trees to Analyze Changes in Tourist Behavior: Tungurahua Case Study. *Lecture notes in networks and systems*. 2022 Jan 1;210–21.
- 11- Zhang S, Yao L, Sun A, Tay Y. Deep Learning Based Recommender System. *ACM Computing Surveys [Internet]*. 2019 Feb 25;52(1):1–38.
- 12- Xue HJ, Dai X, Zhang J, Huang S, Chen J. Deep Matrix Factorization Models for Recommender Systems. *Proceedings of the Twenty-Sixth International Joint Conference on Artificial Intelligence*. 2017 Aug;
- 13- Wikipedia Contributors. Collaborative filtering [Internet]. Wikipedia. Wikimedia Foundation; 2019. Available from: [https://en.wikipedia.org/wiki/Collaborative\\_filtering](https://en.wikipedia.org/wiki/Collaborative_filtering) (accessed 2025-02-06).

## الملاحق

### الملحق التقني (أ):

أولاً: الأدوات المستخدمة في التحليل البياني للاستبيان:

تم استخدام الأدوات التالية لتحليل بيانات الاستبيان:

- لغة البرمجة: Python 3.12.4
- بيئة العمل: Jupyter Notebook 7.0.8
- مكتبات التحليل: pandas لتحميل البيانات وتنظيمها، seaborn و matplotlib لرسم الرسوم البيانية وتحليل البيانات بصريًا. ثانياً: الأكواد البرمجية المستخدمة  
تحميل البيانات ومعاينتها:

```
import pandas as pd
import matplotlib.pyplot as plt
import seaborn as sns
df = pd.read_csv('data.csv')
df.head()
```

تحليل الفئة العمرية:

```
age_group_counts = df['age'].value_counts()
age_group_counts.plot(kind='bar', title='Count of Responses per Age Group', color='skyblue')
plt.xlabel('Age Group')
plt.ylabel('Count')
plt.show()
```

تحليل مستوى الرضا:

```
satisfaction_counts = df['Satisfaction'].value_counts()
satisfaction_counts.plot(kind='pie', autopct='%1.1f%%', startangle=140, colors=sns.color_palette('pastel'))
```

```
plt.title('Distribution of Satisfaction Levels')
plt.ylabel('')
plt.show()
```

لعلاقة بين الخبرة التقنية والنظام المفضل:

```
tech_vs_preference = pd.crosstab(df['Tech Expertise'], df['Preferred System'])
tech_vs_preference.plot(kind='bar', stacked=True, color=sns.color_palette('Set2'))
plt.title('Tech Expertise vs. Preferred System')
plt.xlabel('Tech Expertise')
plt.ylabel('Count')
plt.show()
```

الملحق التقني (ب):

```
public async Task<IActionResult> recommendationmanual()
{
    int userid = Int32.Parse(User.FindFirstValue(ClaimTypes.Sid));
    var userinfo = _context.Users.Where(x => x.Id == userid).FirstOrDefault();
    string un = userinfo.Username;

    List<Trip> langtrip = await _context.Trips.Where(x => x.Language == userinfo.Language).Take(5).ToListAsync();
    ViewBag.recbylang = langtrip;

    List<Trip> tripbyage = await _context.Trips.Where(x => x.Minage < userinfo.Age && x.Maxage > userinfo.Age).Take(5).ToListAsync();
    ViewBag.recbyage = tripbyage;

    //List<Trip> interesttrip = await _context.Trips.Where(x => x.Interest == userinfo.Interest).Take(5).ToListAsync();
    List<Trip> interesttrip = await _context.Trips.Where(x => x.Interest == userinfo.Interest).Distinct().Take(5).ToListAsync();
    ViewBag.interstreclist = interesttrip;

    List<Trip> besttrip = await _context.Trips.Where(x => x.Minage < userinfo.Age && x.Maxage > userinfo.Age
    && x.Language == userinfo.Language && x.Interest == userinfo.Interest).Take(5).ToListAsync();
    ViewBag.recbest = besttrip;

    return View();
}
```

شكل 15: الكود المستخدم للتوصية السياحية التقليدية (القائمة على المحتوى)

```
3 references
public class ModelTrainer
{
    private readonly MLContext _mlContext = new MLContext();
    private ITransformer _model;
    private readonly MyDbContext _context;
    1 reference
    public ModelTrainer(MyDbContext context){_context = context;}
    1 reference
    public async Task InitializeModelAsync()
    {
        var data = await LoadDataAsync(_context);
        // إعداد خط المعالجة دون دمج الأعمدة
        var pipeline = _mlContext.Transforms.Conversion.MapValueToKey(nameof(RepData.UserId))
        .Append(_mlContext.Transforms.Conversion.MapValueToKey(nameof(RepData.TripId)))
        .Append(_mlContext.Recommendation().Trainers.MatrixFactorization(
            new MatrixFactorizationTrainer.Options
            {
                LabelColumnName = nameof(RepData.Rate), // العمود الذي يحتوي على التقييمات
                MatrixColumnIndexColumnName = nameof(RepData.UserId), // المستخدم كفهرس
                MatrixRowIndexColumnName = nameof(RepData.TripId), // الرحلة كفهرس
                NumberOfIterations = 20,
                ApproximationRank = 100
            }
        ));

        _model = pipeline.Fit(data);
    }
    1 reference
    public float Predict(int userId, int tripId)
    {
        var predictionEngine = _mlContext.Model.CreatePredictionEngine<RepData, TripPrediction>(_model);
        var prediction = predictionEngine.Predict(new RepData { UserId = userId, TripId = tripId });
        return prediction.Score;
    }
}
```

شكل 16: الكود المستخدم لبناء نموذج التنبؤ

```

public async Task<IActionResult> RecommendationAI()
{
    // التأكد من تدريب النموذج قبل الاستخدام
    await _modelTrainer.InitializeModelAsync();
    // جلب جميع الرحلات
    var trips = await _context.Trips.ToListAsync();
    var predictions = new List<TripPredictions>();
    // الحصول على معرف المستخدم الحالي
    int userId = Int32.Parse(User.FindFirstValue(ClaimTypes.Sid));
    // الحصول على معرفات الرحلات المختلفة
    var tripIds = await _context.Reps.Select(tr => tr.TripId).Distinct().ToListAsync();
    foreach (int tripId in tripIds)
    {
        // توقع التقييم باستخدام النموذج
        var rate = _modelTrainer.Predict(userId, tripId);
        // جلب تفاصيل الرحلة المرتبطة بالمعرف
        var trip = await _context.Trips
            .Where(x => x.Id == tripId)
            .FirstOrDefaultAsync();

        if (trip != null)
        {
            predictions.Add(new TripPredictions
            {
                TripId = tripId,
                Title = trip.AttractionName,
                Img = trip.Image,
                Prediction = rate
            });
        }
    }
}

```

شكل 17: الكود المستخدم لاستخدام نموذج التدريب في إجراء تنبؤات للمستخدم

الملحق (ت): تفاصيل رياضية وتقنية حول تفكيك المصفوفات ودالة الخسارة

مصفوفة التفاعل (User-Item Interaction Matrix): تمثل العلاقة بين المستخدمين والرحلات السياحية كما في الجدول:

جدول 3 مصفوفة التفاعل (User-Item Interaction Matrix)

Trip 3	Trip 2	Trip 1	User
3	?	5	User 1
?	2	4	User 2

تفكيك المصفوفة: يتم تفكيك المصفوفة الأصلية إلى مصفوفتين أصغر حجماً تُعرفان باسم مصفوفات العوامل الكامنة (Latent Factor Matrices) وهما مصفوفة المستخدمين ومصفوفة العناصر. ولنفترض مثلاً أن عدد العوامل الكامنة = 2 أي أن كل مستخدم وكل رحلة يتم تمثيلها بقيمتين عدديتين في فضاء مخفي فتكون المصفوفتان الناتجتان:

مصفوفة المستخدمين: تمثل المستخدمين في فضاء العوامل الكامنة ونرمز لها بالرمز  $U$  وتكون أبعادها (عدد المستخدمين  $\times$  عدد العوامل الكامنة) أي  $(2 \times 2)$ :

جدول 4: مصفوفة العوامل الكامنة - المستخدمين

Factor 2	Factor 1	User
0.6	0.8	User1
0.3	0.5	User2

مصفوفة العناصر: تمثل العناصر (الرحلات) في فضاء العوامل الكامنة ويرمز لها بالرمز  $V$  وتكون أبعادها (عدد العوامل الكامنة  $\times$  عدد الرحلات) أي  $(3 \times 2)$ :

جدول 5: مصفوفة العوامل الكامنة - الرحلات

Factor 2	Factor 1	Trip
0.4	0.9	Trip 1
0.8	0.2	Trip 2
0.5	0.7	Trip 3

بعد ذلك يتم إعادة بناء المصفوفة الأصلية بتقريب حاصل ضرب المصفوفتين يعبر عنها كالتالي:

$$\hat{R} \approx U \times V^T$$

حيث  $V^T$  هو التحويل (Transpose) لمصفوفة الرحلات (منقول مصفوفة الرحلات).  
مثلاً، القيمة المتوقعة أو التقديرية لتفاعل User1 مع Trip1:

$$\hat{R}_{1,1} = (0.4 \times 0.6) + (0.8 \times 0.9) = 0.24 + 0.72 = 0.96$$

بالمثل، يتم حساب باقي القيم، لكن هذه القيم الأولية ليست دقيقة بما يكفي.  
ولتحسين الدقة، يتم تقليل الفرق بين القيم الحقيقية والتنبؤية بداية باستخدام دالة الخسارة. وتعتبر دالة الخطأ التربيعي (Mean Squared Error - MSE) واحدة من أكثر الدوال انتشاراً وتعطى بالمعادلة التالية:

$$L = \sum_{(i,j) \in K} (R_{ij} - \hat{R}_{ij})^2 + \lambda (\sum_u \|U_u\|^2 + \sum_v \|V_v\|^2)$$

حيث:

$K$ : مجموعة التقييمات المعروفة في المصفوفة الأصلية.

$R_{ij}$ : القيم الحقيقية للتفاعل بين المستخدم والعنصر.

$\hat{R}_{ij}$ : القيم المتوقعة من  $U \times V^T$ .

$\lambda$ : معامل التنظيم (Regularization Term) لتقليل التعقيد ومنع الإفراط في التكيف (Overfitting) ولتقليل تأثير القيم الكبيرة في

المصفوفات وتكوم قيمته 0.1 أو 0.01.

$\|U_u\|^2$  و  $\|V_v\|^2$ : هي مربعات القيم في مصفوفتي  $U$  و  $V$  وتساعد على الحد من القيم الكبيرة جداً في المصفوفات، مما يجعل

النموذج أكثر استقراراً.

ونقوم بحساب الخطأ لكل قيمة معروفة فيكون ناتج الخطأ للخلية الأولى:

$$e_{1,1} = R_{1,1} - \hat{R}_{1,1} = 5 - 0.96 = 4.04 = 16.32$$

وبالمثل، يتم حساب باقي القيم فيكون ناتج الخطأ الإجمالي:

$$\text{Error Sum} \approx 16.3216 + 4.5796 + 11.7649 + 2.7556 \approx 35.4217$$

ثم يتم حساب  $\|U_u\|^2 = (0.8)^2 + (0.6)^2 + (0.5)^2 + (0.3)^2 = 1.34$

وبشكل مشابه يتم حساب  $\|V_v\|^2$  فتكون إجمالي القيم المنتظمة هي 3.73

وبالتالي فتكون نتيجة دالة الخسارة الكلية:

$$L = 35.4217 + (0.1 * 3.73) = 35.79$$

ولتقليل دالة الخسارة وتحسين القيم المتوقعة يتم تحديث مصفوفات  $U$  و  $V$  عبر تحديث القيم تدريجياً بناءً على الخطأ في كل خطوة

باستخدام التحسين التدرجي العشوائي (SGD - Stochastic Gradient Descent).

يتم تحديث مصفوفتي  $U$  و  $V$  باستخدام الصيغ التالية:

$$U_i \rightarrow U_i + \alpha (e_{ij} V_j - \lambda U_i)$$

$$V_j \rightarrow V_j + \alpha (e_{ij} U_i - \lambda V_j)$$

حيث:  $\alpha$ : معدل التعلم (مثلاً 0.01) ومعامل التنظيم (مثلاً 0.1)

مثلاً لنأخذ  $U_1 = [0.8, 0.6]$  و  $V_1 = [0.9, 0.4]$  و  $e_{1,1} = 4.04$  كما نتج معنا سابقاً  $4.04$

$$U_{1,1} = 0.8 + 0.1(4.04 \times 0.9 - 0.1 \times 0.8) = 0.8356$$

بشكل مشابه يتم حساب باقي القيم فتكون مصفوفات العوامل الكامنة كالتالي:

مصفوفة المستخدمين:

Factor 2	Factor 1	User
0.6156	0.8356	User
0.3094	0.5251	User

مصفوفة العناصر (الرحلات):

Factor 2	Factor 1	Trip
0.4238	0.9314	Trip 1
0.8051	0.2025	Trip 2
0.5069	0.7134	Trip 3

وبالتالي تكون مصفوفة التفاعل بعد تحديث جميع القيم المفقودة كالتالي:

Trip 3	Trip 2	Trip 1	User
2.92	3.35	4.89	User 1
2.58	2.06	3.97	User 2

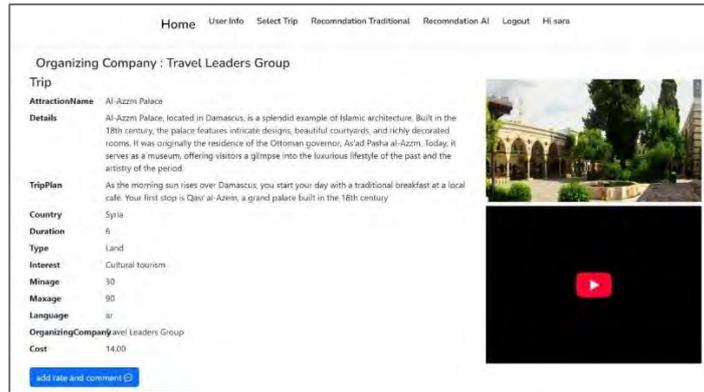
الملحق رقم (ث): الواجهات التفصيلية للنظام:

شكل 18 : صفحة معلومات المستخدم,

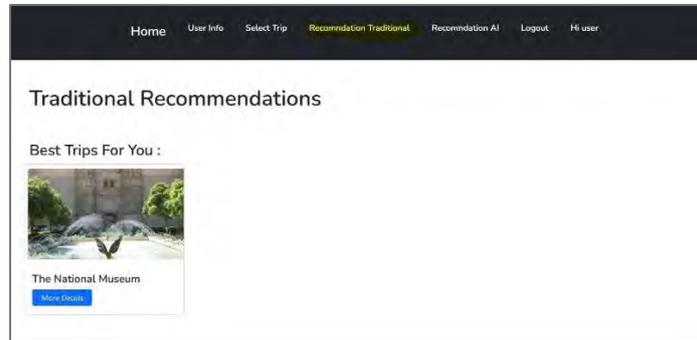
شكل 19: صفحة تحديد الرحلة

عند تحديد الرحلة تظهر شركات الرحلات المسجلة في الموقع وعند تحديد الشركة تظهر تفاصيل الرحلة إذا كانت الشركة تقدم

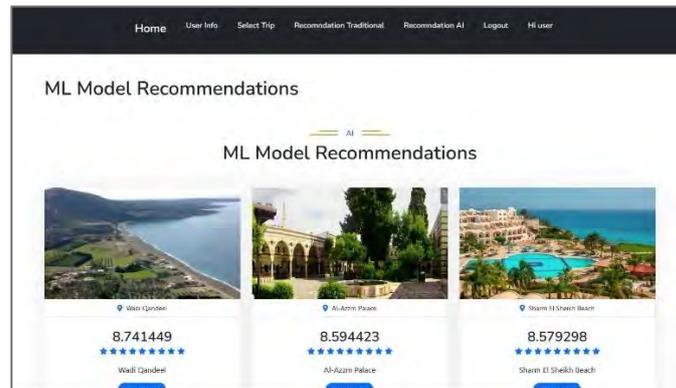
رحلات للمكان المختار:



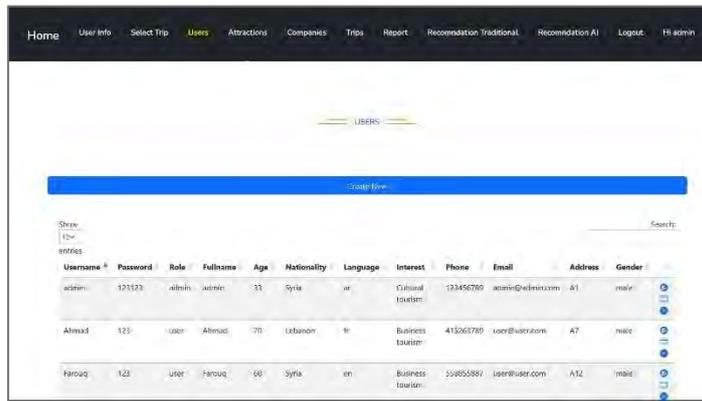
شكل 20: صفحة تفاصيل الرحلة المقدمة من الشركة المختارة



شكل 21: صفحة اختيار رحلة بناءً على التوصيات التقليدية



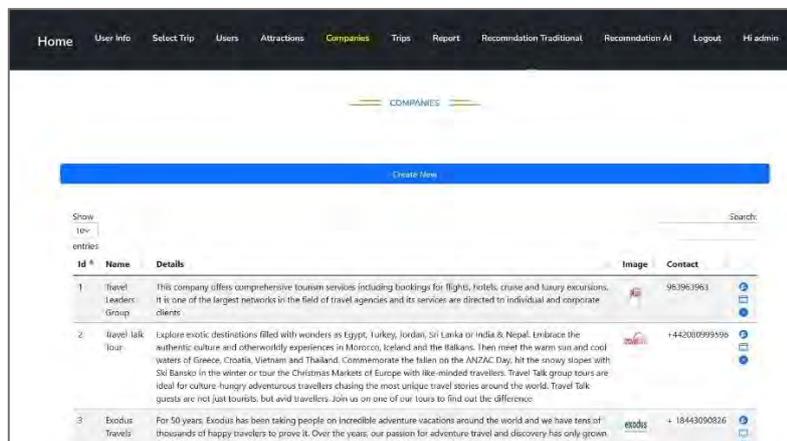
شكل 22: صفحة اختيار رحلة بناءً على التوصيات المعتمدة على الذكاء الاصطناعي



شكل 23 صفحة المستخدمين من قسم المدير



شكل 24 صفحة معالم الجذب من قسم المدير



شكل 25 صفحة الشركات من قسم المدير

The screenshot shows a web application interface for managing trips. At the top, there is a navigation menu with items: Home, User Info, Select Trip, Users, Attractions, Companies, Trips (highlighted), Report, Recommendation Traditional, Recommendation AI, Logout, and Hi admin. Below the menu, there is a 'TRIPS' section with a 'Create Item' button. A search bar is present with the text 'Show 12 entries' and a search icon. The main content is a table with the following data:

Id #	AttractionName	TripPlan	Country	Duration	Type	Interest	Minage	Maxage	Language	OrganizingCompany	Cost
1000	Al-Azmi Palace	-	Syria	6	Land	Cultural tourism	30	90	ar	Travel Leaders Group	14.00
1002	Wadi Dandeel	-	Syria	2	Air	Adventure tourism	5	60	ar	Travel Leaders Group	20.00
1003	Roman Theatre of Palmyra	-	Syria	3	Maritime	Education tourism	30	60	ar	Travel Leaders Group	25.00
1004	Umayyad Mosque	-	Syria	3	Air	Cultural tourism	10	80	ar	Exodus Travels	18.00

شكل 26 صفحة الرحلات من قسم المدير