

دراسة تحسين دقة تحديد المواقع الداخلية عبر Wi-Fi RSSI باستخدام تقنيات معالجة البيانات وخوارزميات التعلم الآلي: دراسة تجريبية لبيئة تعليمية بكلية العلوم التقنية - مصراتة (CTSM)

محمود محمد محمد الصغير¹، عبد العزيز محمود سليمان سويب^{2*}
^{1,2} قسم الحاسوب، كلية العلوم التقنية، مصراتة، ليبيا

A study to improve indoor positioning accuracy via Wi-Fi RSSI using data processing techniques and machine learning algorithms: An experimental study of an educational environment at the College of Technical Sciences - Misurata (CTSM)

Mahmoud Mohamed Elsaghayer¹، Abdulaziz Mahmud Suwayeb^{2*}
^{1,2} Computer Department، Collage of Technical Sciences، Misurata، Libya

*Corresponding author: aswaype@gmail.com

Received: May 26, 2025

Accepted: July 22, 2025

Published: July 31, 2025

المخلص

تكتسب أنظمة تحديد المواقع الداخلية (IPS) أهمية متزايدة في التطبيقات التي تتطلب تتبعاً دقيقاً داخل المباني. تعتمد العديد من هذه الأنظمة على تقنية بصمة قوة إشارة Wi-Fi المستقبلة RSSI (Wi-Fi Received Signal Strength Indicator) لتحسين دقة تحديد المواقع الداخلية في الطابق الأول لمبنى كلية العلوم التقنية - مصراتة بمساحة تبلغ (43.24 متر * 66.71 متر) باستخدام 13 نقطة وصول بمواقعها الأصلية. تم تطبيق تطبيع Z-score على بيانات RSSI باستخدام نموذج التظليل اللوغاريتمي للمسافة. تمت مقارنة أداء خوارزمية KNN التقليدية مع نسخة محسنة تعتمد على الترجيح (Weighted KNN - WKNN) عبر قيم مختلفة للمعامل K (عدد الجيران الأقرب). أظهرت النتائج أن القيمة المثلى K=9 تحقق أفضل متوسط خطأ في المسافة (MDE) لكلا الخوارزميتين بعد التطبيع. حققت WKNN تحسناً طفيفاً مقارنة بـ KNN حيث بلغ MDE حوالي 3.28 متر لـ WKNN مقابل 3.31 متر لـ KNN عند K=9. كما أظهرت WKNN دقة أعلى بشكل طفيف ضمن هوامش خطأ مختلفة (مثل 56% مقابل 55% ضمن 3 أمتار، و 83% مقابل 82% ضمن 5 أمتار). يساهم العمل في تقييم و تطبيق أنظمة تحديد مواقع داخلية أكثر كفاءة و موثوقية في البيئات التعليمية.

الكلمات المفتاحية: خوارزمية KNN، خوارزمية WKNN، RSSI، تطبيع z-score، المسافة الإقليدية.

Abstract

Indoor Positioning Systems (IPS) are becoming increasingly important in applications that require accurate indoor tracking. Many of these systems rely on the Wi-Fi RSSI (Wi-Fi Received Signal Strength Indicator) fingerprint technology for its ability to leverage existing wireless infrastructure. The K-Nearest Neighbors (KNN) algorithm is commonly used. But its accuracy is affected by RSSI fluctuations. This study aims to improve the indoor positioning performance on the first floor of the Faculty of Technical Sciences - Misurata building with an area of (43.24 m * 66.71 m) using 13 access points with their original locations. Z-score normalization was applied to the RSSI data using a logarithmic distance shading model. The

performance of the traditional KNN algorithm was compared with an improved weight-based version (Weighted KNN - WKNN) across different values of the parameter K (number of nearest neighbors). The results showed that the optimal value of K=9 achieves the best mean distance error (MDE) for both algorithms after normalization. WKNN achieved a slight improvement compared to KNN with an MDE of about 3.28 meters for WKNN versus 3.31 meters for KNN at K=9. WKNN also showed slightly higher accuracy within different error margins (e.g. 56% vs. 55% within 3 meters, and 83% vs. 82% within 5 meters). The work contributes to the evaluation and implementation of more efficient and reliable indoor positioning systems in educational environments.

Keywords: KNN algorithm, WKNN algorithm, RSSI, Z-score normalization, Euclidean distance.

مقدمة

أحدث التطورات المتسارعة في تقنيات اللاسلكية و الانتشار الواسع للأجهزة المحمولة ثورة في كيفية تفاعلنا مع البيئات المحيطة بنا ، لاسيما داخل المباني و المساحات المغلقة حيث تفقد أنظمة تحديد المواقع العالمية (GPS) فعاليتها. نتيجة لذلك ، برزت الحاجة الماسة إلى تطوير أنظمة تحديد المواقع الداخلية (Indoor Positioning System - IPS) القادرة على توفير معلومات دقيقة حول موقع المستخدمين أو الأصول في الوقت الفعلي. تجد هذه الأنظمة تطبيقات واسعة في مجالات متنوعة تشمل الملاحة داخل المباني الكبيرة ، و تتبع الأصول، و توفير خدمات قائمة على الموقع ، و تعزيز السلامة و الأمن ، في السياق التعليمي، مثل كلية العلوم التقنية -مصراتة (CTSM) ، يمكن لهذه الأنظمة أن تدعم تطبيقات مثل تتبع حضور الطلاب ، و إدارة استخدام المختبرات و المرافق، و توجيه الزوار و الطلاب الجدد ، و توفير خدمات معلوماتية مخصصة للموقع.[1][2] .

من بين التقنيات المتعددة المستخدمة في أنظمة تحديد المواقع الداخلية ، اكتسبت تقنية بصمة قوة الإشارة المستقبلية لشبكات الواي فاي RSSI اهتماما كبيرا نظرا لميزتها الجوهرية المتمثلة في إمكانية الاستفادة من البنية التحتية لشبكات Wi-Fi المنتشرة بالفعل في معظم المباني الحديثة ، بما في ذلك مباني CTSM ، مما يقلل من تكاليف النشر و التركيب ، يعتمد مبدأ تحديد المواقع باستخدام بصمة RSSI على مرحلتين رئيسيتين: مرحلة التدريب (Offline Phase) و مرحلة التشغيل (Online Phase). في مرحلة التدريب يتم إنشاء قاعدة بيانات مرجعية (خريطة الإشارة اللاسلكية) عن طريق قياس و تسجيل قيم RSSI من نقاط الوصول (APs) المتاحة عند مواقع مرجعية (RPs)، معروفة الأحداثيات داخل البيئة المستهدفة . أما في مرحلة التشغيل ، فيقوم المستخدم بقياس قيم RSSI الحالية ، ثم تتم مقارنة هذه القياسات مع البصمات المخزنة في قاعدة البيانات المرجعية باستخدام خوارزمية تصنيف مناسبة لتقدير موقع المستخدم.[3][4] .

تعد خوارزمية K-Nearest Neighbors (KNN) واحدة من أكثر خوارزميات التصنيف شيوعا و بساطة و فعالية في تطبيقات تحديد المواقع المعتمدة على بصمة RSSI. تقوم الخوارزمية بحساب المسافة (عادة الإقليدية) بين بصمة RSSI المقاسة حاليا و جميع البصمات في خريطة الراديو. ثم تحدد أقرب K بصمة مرجعية ، و يتم تقدير الموقع الحالي كمتوسط (أو متوسط مرجح) لمواقع هذه الجيران الأقرب، على الرغم من بساطتها ، تواجه KNN تحديات تتعلق بتقلبات إشارة RSSI و الحاجة إلى معالجة البيانات و اختيار قيمة K المثلى لتحقيق أفضل دقة ، خاصة في البيئات الكبيرة مثل مبنى CTSM.[5][6] .

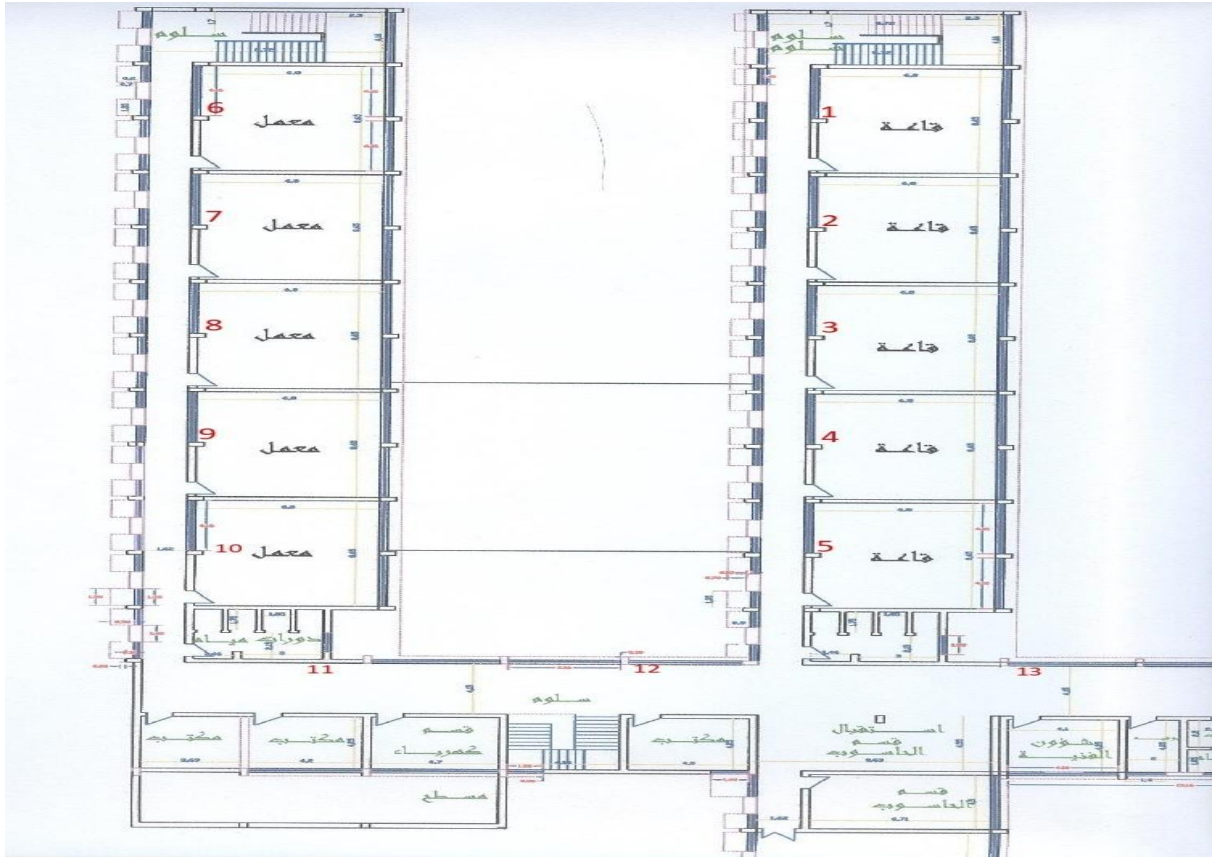
تهدف هذه الورقة البحثية إلى دراسة و تحسين أداء نظام تحديد المواقع الداخلية القائم على Wi-Fi RSSI في البيئة المحددة لمبنى كلية العلوم التقنية - مصراتة، مع الأخذ في الاعتبار الأبعاد المحددة (66.71*43.24 متر) و استخدام 13 نقطة وصول بمواقعها الأصلية المستخرجة من المخطط. سيتم التركيز على مقارنة أداء خوارزمية KNN التقليدية مع نسخة محسنة منها، وهي خوارزمية الجيران الأقرب الموزونة (Weighted K-Nearest Neighbors - WKNN) مع استخدام تطبيع Z-score لمعالجة بيانات RSSI، سيتم تقييم الأداء باستخدام مقاييس دقيقة مثل متوسط الخطأ في المسافة (MDE) و دقة تحديد الموقع ضمن هوامش خطأ مختلفة، و تقديم نتائج مفصلة لتقييم التحسينات المقترحة [1][7].

المنهجية

يصف هذا القسم بالتفصيل الإجراءات التجريبية المتبعة في هذه الدراسة لتقييم وتحسين أداء خوارزميات تحديد المواقع الداخلية باستخدام البصمة اللاسلكية Wi-Fi RSSI في البيئة المحددة للطابق الأول بمبنى كلية العلوم التقنية – مصراتة CTSM.

تشمل المنهجية اعداد البيئة التجريبية، جمع البيانات، معالجة البيانات، و تنفيذ وتقييم خوارزميتي KNN و WKNN ، مع التركيز على الأسس الرياضية لكل خطوة.

1. إعداد بيئة التجربة : تم تصميم بيئة التجربة على الطابق الاول من مبنى كلية العلوم التقنية – مصراتة CTSM و الذي يمتد على مساحة مستطيلة تبلغ 66.71 مترا طولاً (المحور X) و 43.24 مترا عرضاً (المحور Y). ثم استخدام المواقع الاصلية لـ 13 نقطة وصول (APs) من نوع Wi-Fi قياسي، و التي تم استخلاصها من المخطط المعماري الأصلي للمبنى المبين بالشكل (1).



الشكل (1) : الشكل المعماري للطابق الأول بكلية العلوم التقنية مصراتة.

تم انشاء شبكة من النقاط المرجعية (RPs) بتوزيع منتظم بفاصل 2.5 متر، مما نتج عنه 459 نقطة مرجعية فعلية (x_{rp}, y_{rp}) لكل نقطة . كما تم تحديد 150 نقطة اختبار (x_{tp}, y_{tp}) في مواقع عشوائية لتقييم الأداء.

2. جمع بيانات RSSI لإنشاء قاعدة بيانات لقوة الإشارة اللاسلكية، تم استخدام نموذج انتشار الإشارة اللوغاريتمي للمسافة مع إضافة تأثير التظليل العشوائي (Long-normal shadowing model). يفترض هذا النموذج أن قوة الإشارة المستقبلية (بالديسيبل مللي واط، dBm) تتناقص لوغاريتميا مع المسافة و تتأثر بتقلبات عشوائية تتبع توزيعاً طبيعياً. يتم تمثيل النموذج بالمعادلة التالية:

$$RSSI(d) = P_0 - 10.n.log_{10}(d) + X_{\sigma} \quad (1)$$

حيث :

$RSSI(d)$: هي قوة الإشارة المستقبلية على مسافة d

P_0 : هي قوة الإشارة المستقبلية على مسافة مرجعية (عادة 1 متر)

n : هو معامل فقدان المسار (Path Loss Exponent) الذي يعتمد على خصائص البيئة

d : هي المسافة الإقليدية بين جهاز الإرسال (AP) و جهاز الاستقبال (RP أو TP)

X_σ : هو متغير عشوائي يتبع توزيعاً طبيعياً بمتوسط صفر و انحراف معياري σ (بالديسيل) ويمثل تأثير التظليل في هذه المحاكاة تم استخدام نفس معلمات النموذج كما في الدراسة المرجعية للحفاظ على الاتساق:

$$\sigma = 4\text{dB}, n = 3.5, P_0 = -40\text{dBm}$$

تم حساب المسافة الإقليدية d_{ij} بين كل نقطة استقبال (سواء كانت نقطة مرجعية أو نقطة اختبار) i وكل نقطة وصول j باستخدام المعادلة القياسية:

$$d_{ij} = \sqrt{(x_i - x_{ap,j})^2 + (y_i - y_{ap,j})^2} \quad (2)$$

حيث (x_i, y_i) هي إحداثيات نقطة الاستقبال و $(x_{ap,j}, y_{ap,j})$ هي إحداثيات نقطة الوصول j . تم تطبيق المعادلة (1) باستخدام المسافات المحسوبة (المعادلة 2) لكل زوج (نقطة استقبال ، نقطة وصول) للحصول على بصفة RSSI كاملة (متجه من 13 قيمة) لكل موقع مرجعي و نقطة اختبار.

3- معالجة البيانات الأولية قبل تطبيق خوارزمية تحديد الموقع تم اجراء خطوتين لمعالجة بيانات RSSI الأولية:

ا- التعامل مع القيم الضعيفة: تم استبدال أي قراءة RSSI أقل من -100 dBm بالقيمة -100 dBm

يمثل هذا الحد الأدنى للإشارة التي يمكن اكتشافها بشكل موثوق و يساعد في تجنب تأثير القيم المنخفضة جداً و غير الواقعية.

ب- تطبيع البيانات (Z-score Normalization): نظراً لأن الخوارزميتين KNN و WKNN تعتمدان على حساب المسافات متجهات RSSI ، فإن الاختلاف في متوسط و مقياس قيم RSSI بين نقاط الوصول المختلفة يمكن أن يؤثر سلباً على الأداء. لمعالجة ذلك تم تطبيق تطبيع Z-score على بيانات RSSI لكل نقطة وصول j على حدة عبر مجموعة بيانات النقاط المرجعية (459 نقطة).

تم حساب متوسط μ_j و الانحراف لمعياري σ_j لقيم RSSI لنقطة الوصول j عبر جميع النقاط المرجعية . ثم تم تحويل كل قراءة أصلية r_{ij} (القراءة من AP j عند النقطة i) إلى قيمة مطبوعة r'_{ij} باستخدام المعادلة :

$$r'_{ij} = \frac{r_{ij} - \mu_j}{\sigma_j} \quad (3)$$

تم استخدام قيم μ_j و σ_j المحسوبة من بيانات التدريب (النقاط المرجعية) لتطبيع بيانات نقاط الاختبار (150) لضمان الاتساق و تجنب تسرب المعلومات من مجموعة الاختبار إلى عملية التدريب [1][3].

4- تطبيق خوارزمية تحديد الموقع و تقييمها تم باستخدام خوارزميتي K-Nearest Neighbors (KNN) و (

Weighted K-Nearest Neighbors (WKNN) لتقدير موقع نقاط الاختبار باستخدام بيانات RSSI المطبوعة.

أ- خوارزمية KNN التقليدية

1. حساب المسافة لكل نقطة اختبار TP_i ذات بصفة RSSI مطبوعة $r'_{tp,i}$ تم حساب المسافة الإقليدية

بينها و بين كل نقطة مرجعية RP_m ذات بصفة مطبوعة $r'_{rp,m}$ باستخدام المعادلة :

$$D(TP_i, RP_m) = \sqrt{\sum_{j=1}^{13} (r'_{tp,ij} - r'_{rp,mj})^2} \quad (4)$$

2. تحديد الجيران الأقرب : تم ترتيب جميع النقاط المرجعية بناء على مسافتها المحسوبة $D(TP_i, RP_m)$ من نقطة الاختبار TP_i . تم تحديد مجموعة $N_k(TP_i)$ التي تحتوي على اقرب K نقطة مرجعية .
3. تقدير الموقع : تم تقدير موقع نقطة الاختبار $(\hat{x}_{tp,i}, \hat{y}_{tp,i})$ عن طريق حساب المتوسط البسيط لإحداثيات (Y, X) للجيران الأقرب لـ k في مجموعة $N_k(TP_i)$:

$$\hat{x}_{tp,i} = \frac{1}{k} \sum_{RP_m \in N_k(TP_i)} x_{rp,m} \quad (5)$$

$$\hat{y}_{tp,i} = \frac{1}{k} \sum_{RP_m \in N_k(TP_i)} y_{rp,m} \quad (6)$$

ب- خوارزمية WKNN المحسنة تتبع خوارزمية WKNN نفس الخطوتين الأولى (حساب المسافة و تحديد الجيران الأقرب) مثل KNN. الاختلاف الرئيسي يكمن في خطوة تقدير الموقع ، حيث يتم إعطاء وزن أكبر للنقاط المرجعية الأقرب في فضاء الإشارة.

1. حساب الأوزان: لكل جار RP_m في مجموعة الجيران الأقرب $N_k(TP_i)$ ، تم حساب وزن ω_m يعتمد على معكوس المسافة الإقليدية المحسوبة من المعادلة (4):

$$\omega_m = \frac{1}{D(TP_i, RP_m) + \epsilon}$$

حيث ϵ هي قيمة صغيرة جدا (مثل 10^{-6}) تضاف لتجنب القسمة على صفر في حالة تطابق الاختبار تماما مع بصمة مرجعية.

2. تقدير الموقع (المتوسط الموزون): تم تقدير موقع نقطة الاختبار $(\hat{x}_{tp,i}, \hat{y}_{tp,i})$ عن طريق حساب المتوسط الموزون لإحداثيات الجيران الأقرب لـ k باستخدام الأوزان المحسوبة:

$$\hat{x}_{tp,i} = \frac{\sum_{RP_m \in N_k(TP_i)} \omega_m \cdot x_{rp,m}}{\sum_{RP_m \in N_k(TP_i)} \omega_m} \quad (7)$$

$$\hat{y}_{tp,i} = \frac{\sum_{RP_m \in N_k(TP_i)} \omega_m \cdot y_{rp,m}}{\sum_{RP_m \in N_k(TP_i)} \omega_m} \quad (8)$$

ج - مقاييس التقييم لتقييم أداء كل من KNN و WKNN تم استخدام المقاييس التالية :

- 1- خطأ المسافة (Distance Error - DE) : لكل نقطة اختبار TP_i ، تم حساب خطأ المسافة الإقليدية بين الموقع المقدّر $(\hat{x}_{tp,i}, \hat{y}_{tp,i})$ و الموقع الفعلي $(x_{tp,i}, y_{tp,i})$:

$$DE_i = \sqrt{(\hat{x}_{tp,i} - x_{tp,i})^2 + (\hat{y}_{tp,i} - y_{tp,i})^2} \quad (9)$$

- 2- متوسط خطأ المسافة (Mean Distance Error - MDE) : تم حساب متوسط أخطاء المسافة لجميع نقاط الاختبار (حيث $150N_{tp}$) :

$$MDE = \frac{1}{N_{tp}} \sum_{i=1} DE_i \quad (10)$$

- 3- دقة تحديد الموقع (Accuracy at threshold): تم حساب النسبة المئوية لنقاط الاختبار التي كان خطأ المسافة

DE_i الخاص بها أقل من أو يساوي عتبي خطأ معينة T (مثل 1، 2، 3، 5، 7، 10)

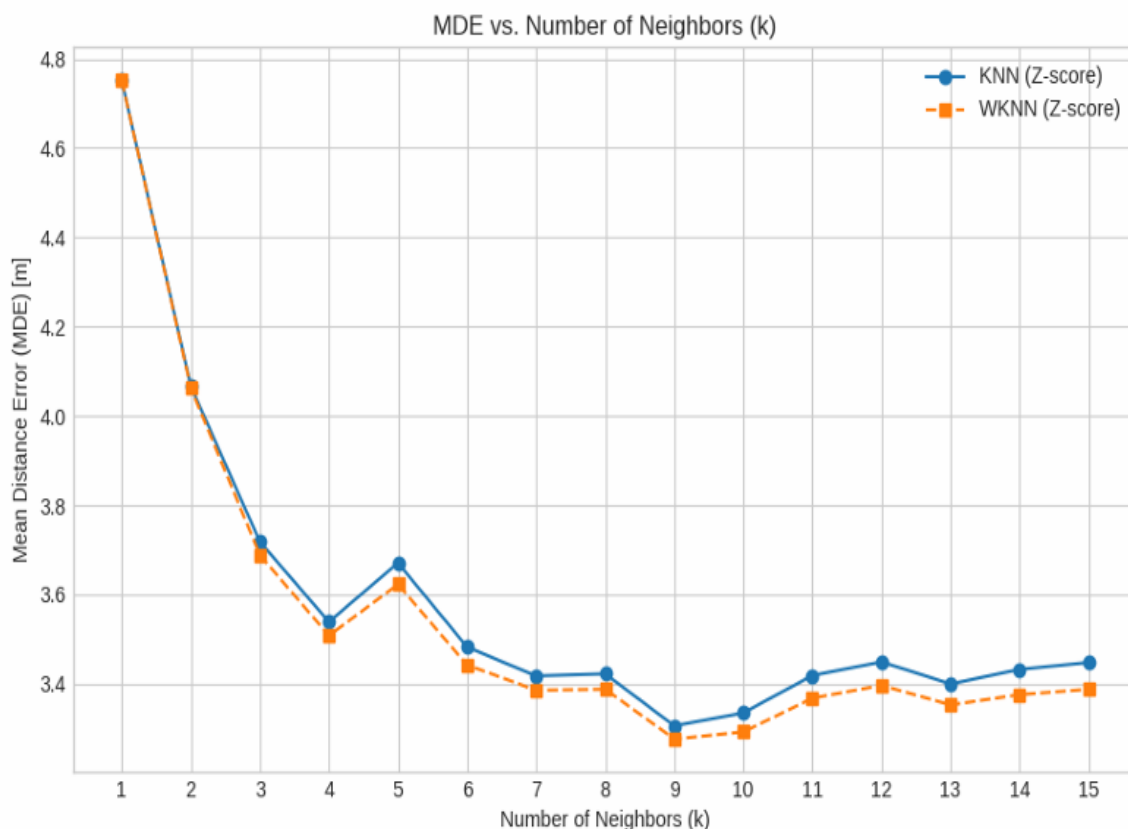
تم تكرار عملية التقييم هذه باستخدام بيانات RSSI المطبوعة (Z-score) لقيم مختلفة لـ K (من 1 إلى 15) لكلا الخوارزميتين (KNN و WKNN) لتحديد الإعداد الأمثل و مقارنة الأداء بينهما في سياق مبنى CTSM [1] [5] [6] [8].

النتائج

يقدم هذا القسم النتائج المستمدة من تطبيق و تقييم خوارزميتي KNN و WKNN لتحديد المواقع الداخلية في بيئة مبنى كلية العلوم التقنية – مصراتة (43.24 * 66.71 متر و 13 نقطة وصول لمواقعها الاصلية) باستخدام بيانات RSSI المطبوعة (Z-score). تم تحليل تأثير تغيير قيمة 'K' (عدد الجيران الأقرب) من 1 إلى 15 على مقاييس الأداء الرئيسية : متوسط خطأ المسافة (MDE) و دقة تحديد الموقع ضمن هوامش خطأ مختلفة (م 1 ، م 2 ، م 3 ، م 5 ، م 7 ، م 10).

1. تأثير قيمة 'K' على متوسط المسافة (MDE) : تم حساب متوسط خطأ المسافة (MDE) بين المواقع المقدرة بواسطة KNN و WKNN و المواقع الفعلية لنقاط الاختبار (150 نقطة) و ذلك لقيم مختلفة للمعلمة 'K'. يوضح الشكل 1 المقارنة بين أداء الخوارزميتين من حيث MDE.

الشكل 2 : مقارنة خطأ المسافة (MDE) بالمتر مقابل قيم مختلفة لـ K (من 1 إلى 15) لخوارزميتي KNN و WKNN باستخدام تطبيع Z-score.




الشكل 2 : مقارنة خطأ المسافة (MDE) مقابل قيم مختلفة لـ K.

يظهر الشكل 2 ان كلا الخوارزميتين تتبعان نمطا مشابها، حيث ينخفض MDE بشكل عام مع زيادة قيمة K ، ليصل إلى منطقة استقرار أو تحسن طفيف عند قيم K الأعلى . بالنسبة لخوارزمية KNN التقليدية ، تم تحقيق أقل MDE (حوالي 3.31) عند k=9. اما بالنسبة لخوارزمية WKNN المحسنة، فقد استمر التحسن الطفيف مع زيادة K ، وتم تحقيق أقل MDE (حوالي 3.28 متر) عند K=9 ، و لكنه ظل منخفضا جدا عند قيم K الأعلى ، مثل 3.35 متر عند K=13

بشكل عام تظهر WKNN تحسنا طفيفا في MDE مقارنة بـ KNN ، خاصة عند القيم المتوسطة و العليا لـ K ، عبر معظم قيم KNN

2. تأثير قيمة 'K' على دقة تحديد الموقع: تم تقييم دقة تحديد الموقع كنسبة مئوية للتقديرات التي تقع ضمن نصف قطر خطأ معين T ، يوضح شكل 3 مقارنة الدقة ضمن 3 أمتار و 5 أمتار لقيم K المختلفة لكلا الخوارزميتين.

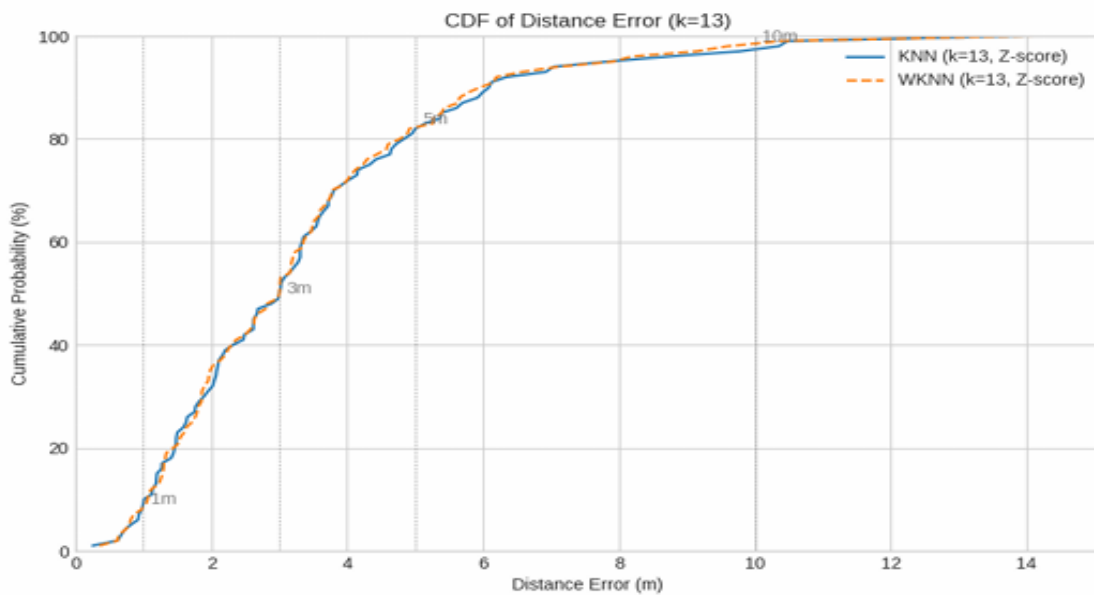
الشكل 3 : مقارنة دقة تحديد الموقع (كنسبة مئوية) ضمن 3 أمتار و 5 أمتار مقابل قيم مختلفة لـ K لخوارزميتي KNN و WKNN باستخدام تطبيع Z-score.



الشكل 3 : مقارنة دقة تحديد الموقع مقابل قيم مختلفة لـ K لـ KNN و WKNN باستخدام تطبيق Z-score.

يتضح من الشكل 3 أن دقة التصنيف ضمن 3 أمتار ($Acc@3m$) تتحسن بشكل ملحوظ مع زيادة K لكلا الخوارزميتين، و تصل إلى ذروتها عند $K=9$ تقريبا (حوالي 55% لـ KNN و 56% لـ WKNN) و بالمثل تظهر الدقة ضمن 5 أمتار ($Acc@5m$) في الشكل 3 تحسنا مع زيادة K ، و تصل حوالي 82-83% عند قيم K الأعلى (مثل $K=9$ و ما فوق) لكلا الخوارزميتين. مرة أخرى تظهر KNN تفوقا طفيفا أو أداءا مشابها لـ KNN من حيث الدقة عند معظم قيم K .

3. دالة التوزيع التراكمي (CDF): لخطأ تحديد الموقع لتوفير نظرة شاملة على توزيع أخطاء تحديد الموقع (DE_i) عند قيمة K المثلى التي أظهرت أفضل توازن بين MDE و الدقة (تم اختيار $K=9$ بناء على أقل MDE). تم رسم دالة التوزيع التراكمي (CDF) للأخطاء لكلا الخوارزميتين كما هو موضح في الشكل 4. الشكل 4: دالة التوزيع التراكمي (CDF) لخطأ تحديد الموقع (بالمتر) عند استخدام الأعداد الأمثل ($k=9$) لخوارزميتي KNN و WKNN مع تطبيق Z-score تظهر الخطوط المنقطعة و النصوص المرفقة قيم الدقة عند هوامش خطأ محدد.



الشكل 4: دالة التوزيع التراكمي (CDF) لخطأ تحديد الموقع عند استخدام الأعداد الأمثل ($k=9$).

يؤكد الشكل 4 النتائج السابقة. عند $K=9$: KNN : حققت MDE يبلغ 3.31 متر. بلغت الدقة حوالي 8% ضمن 1 متر. 29% ضمن 2 متر ، 55% ضمن 3 أمتار، 82% ضمن 5 أمتار، 95% ضمن 7 أمتار، 98% ضمن 10 أمتار .

WKNN : حققت MDE يبلغ 3.28 متر(تحسن طفيف). بلغت الدقة حوالي 9% ضمن 1 متر. 30% ضمن 2 متر ، 56% ضمن 3 أمتار، 83% ضمن 5 أمتار، 95% ضمن 7 أمتار، 98% ضمن 10 أمتار .

تظهر مقارنة منحنيات CDF أن منحنى WKNN يقع بشكل عام إلى يسار منحنى KNN ، مما يشير إلى أن WKNN تميل إلى تحقيق أخطاء أصغر بشكل طفيف مقارنة بـ KNN عند نفس قيمة K المثلث .

4. ملخص الجداول الرقمية: يلخص الجدول التالي النتائج الرقمية الرئيسية لأداء KNN و WKNN عند القيمة المثلث $K=9$ باستخدام تطبيق Z-score.

الجدول 1: ملخص مقارنة أداء KNN و WKNN عند $K=9$ مع تطبيق Z-score.

الخوارزمية	K	MDE (m)	Acc@1m (%)	Acc@2m (%)	Acc@3m (%)	Acc@5m (%)	Acc@7m (%)	Acc@10m (%)
KNN	9	3.31	8.0	29.0	55.0	82.0	95.0	98.0
WKNN	9	3.28	9.0	30.0	56.0	83.0	95.0	98.0

تؤكد النتائج الرقمية و الرسوم البيانية أن كلا الخوارزميتين يمكنهما تحقيق دقة تحديد موقع جيدة في مبنى CTSM . أظهرت خوارزمية WKNN تحسناً طفيفاً و لكنه ثابت في الأداء مقارنة بخوارزمية KNN التقليدية عند استخدام نفس قيمة K المثلث و معالجة البيانات باستخدام تطبيق Z-score.

المناقشة

تناقش هذه الورقة أداء خوارزميتي KNN و WKNN لتحديد المواقع الداخلية باستخدام بصمة Wi-Fi RSSI في بيئة مبنى تعليمي . أظهرت النتائج أن كلا الخوارزميتين قادرتان على توفير دقة تحديد موقع مقبولة ، مع تفوق طفيف و مستمر لخوارزمية WKNN . يعزى هذا التحسن إلى آلية الترجيح التي تمنح أهمية أكبر للجيران الأقرب في فضاء الإشارة ، مما يقلل من تأثير النقاط البعيدة أو الشاذة التي قد تؤثر سلباً على دقة التقدير في KNN التقليدية.

تأثير تطبيق Z-score: كان لتطبيق تطبيق Z-score تأثير إيجابي على أداء كلا الخوارزميتين . يساعد هذا التطبيق في توحيد مقياس قيم RSSI عبر نقاط الوصول المختلفة، مما يقلل من التحيزات المحتملة الناتجة عن الاختلاف في قوة إشارة أجهزة الإرسال أو خصائص الانتشار. هذا يضمن أن المسافات المحسوبة بين بصمات RSSI تعكس بشكل أكثر دقة التشابه الفعلي بين المواقع.

اختيار قيمة K: أظهرت النتائج أن قيمة $k=9$ كان الأمثل لكلا الخوارزميتين في هذه البيئة المحددة . تشير هذه القيمة إلى وجود توازن جيد بين تقليل تأثير الضوضاء (عن طريق أخذ متوسط لعدد كاف من الجيران) و تجنب التنعيم المفرط الذي قد يحدث مع قيم K الكبيرة جداً، مما يؤدي إلى فقدان التفاصيل المحلية. القيم الصغيرة جداً لـ K (مثل $K=1$) تجعل النظام حساساً للضوضاء ، بينما القيم الكبيرة جداً قد تؤدي إلى تقديرات أقل دقة بسبب تضمين جيران بعيدين جداً.

الخاتمة

قدمت هذه الدراسة تقييماً و تحسناً لأداء أنظمة تحديد المواقع الداخلية القائمة على بصمة Wi-Fi RSSI باستخدام خوارزميتي KNN و WKNN في الطابق الأول بمبنى كلية العلوم التقنية – مصراتة.

أظهرت النتائج أن تطبيق تطبيق Z-score و تحسين خوارزمية KNN و WKNN يوفر تحسناً طفيفاً و لكنه ثابت في دقة تحديد الموقع . كانت القيمة المثلث لعدد الجيران الأقرب (K) هي 9 لكلا الخوارزميتين ، مما حقق متوسط خطأ في المسافة يبلغ 3.28 متر لـ WKNN و 3.31 متر لـ KNN . تؤكد هذه النتائج على إمكانية استخدام تقنيات تحديد المواقع الداخلية القائمة على Wi-Fi بكفاءة في البيئات التعليمية ، و تفتح آفاقاً للبحث المستقبلي نحو أنظمة أكثر قوة و دقة في التطبيقات الواقعية.

- [1] An Improved Weighted K-Nearest Neighbor Algorithm for Indoor Localization. ResearchGate. (2025, May 2). https://www.researchgate.net/publication/347614407_An_Improved_Weighted_KNearest_Neighbor_Algorithm_for_Indoor_Localization
- [2] Machine Learning-Based WiFi Indoor Localization with FasterKAN. ESPublisher. (2024, October 28). https://www.espublisher.com/uploads/article_pdf/es1289.pdf
- [3] Indoor Localization Methods for Smartphones with Multi-Source. MDPI. (2025, March 14). <https://www.mdpi.com/1424-8220/25/6/1806>
- [4] An Enhanced Indoor Positioning Method Based on RTT and RSS. IEEE Xplore. (2024, October 1). <https://ieeexplore.ieee.org/iel8/7361/10704012/10643433.pdf>
- [5] A device free high-precision indoor positioning and tracking method. Nature. (2025, May 21). <https://www.nature.com/articles/s41598-025-02876-1>
- [6] High accuracy indoor positioning system using Galois field-based. Nature. (2025, April 29). <https://www.nature.com/articles/s41598-025-97715-8>
- [7] Local Batch Normalization-Aided CNN Model for RSSI-Based. MDPI. (2025, March 13). <https://www.mdpi.com/2079-9292/14/6/1136>
- [8] Anomaly detection using machine learning and adopted digital twin. Nature. (2025, May 26). <https://www.nature.com/articles/s41598-025-02759-5>