المجلة الجغرافية العربية

تصدر عن الجمعية الجغرافية المصرية

استخلاص أسطح المباني وأنواعها من بيانات الليدار باستخدام التقنيات الجيومكانية والتصنيف الهدفي لمجموعة من أحياء مدينة الرياض

أ. محمد بن خالد العنقري

طالب الدكتوراه في علم المعلومات الجغرافية – قسم الجغرافيا – جامعة الملك سعود

أ.د. فرحان بن حسين الجعيدي

أستاذ بقسم الجغرافيا – جامعة الملك سعود

CC BY NC

كافة حقوق النشر محفوظة للجمعية الجغرافية المصرية
وجميع الأراء الواردة في بحوث هذه السلسلة تعبر عن آراء
أصحابها ولا تعبر بالضرورة عن وجهات نظر الجمعية الجغرافية المصرية

الترقيم الدولي الموحد للطباعة: ١١١٠ – ١٩١١

الترقيم الدولي الموحد الإلكتروني: ٢٦٨٢ – ٤٧٩٥

الموقع على شبكة الانترنت: www.egyptiangs.com

All rights reserved. This book is protected by copyright. No part of it may be reproduced, stored in a retrieval system, or transmitted in any form or by any means, electronic, mechanical, photocopying, recording, or otherwise, without written permission from The Egyptian Geographical Society.

قواعد النشر

تهدف هذه السلسلة إلى نشر البحوث الجغرافية الأصيلة التي يقوم بها الجغرافيون المصريون المتخصصون، بهدف تعريف المؤسسات العلمية العالمية والعربية بالنشاط العلمي الذي تتبناه وتتوفر عليه الجمعية الجغرافية المصرية.

وتقوم بحوث هذه السلسلة" على الدراسات الجغرافية الميدانية، وعلى البحوث التي تهتم بطرح رؤى جديدة في مناهج البحث الجغرافي وأساليبه، كما تعنى بالبحوث النفعية في مختلف مجالات الجغرافيا التطبيقية، وهو ما يتيح للجغرافيين العرب والأجانب الإطلاع على ما تقوم به الجمعية الجغرافية المصرية التي تعد أقدم الجمعيات الجغرافية في العالم العربي، كما تعد رائدة في إجراء البحوث والدراسات الجغرافية الجادة والأصلية.

وقد تتضمن بحوث هذه "السلسلة" ملخصات مكثفة لرسائل الماجستير والدكتوراة المجازة في الجامعات المصرية والعربية وغيرها.

ويشترط في البحوث التي تنشر ضمن هذه السلسلة مراعاة القواعد التالية:

- تقبل للنشر في هذه السلسلة البحوث التي تتسم بالأصالة وتسهم في تقدم المعرفة الجغرافية.
- يقدم مع البحوث المكتوبة باللغة العربية ملخص (Abstract) باللغة الإنجليزية. كما يقدم مع البحوث المكتوبة بلغة أجنبية ملخص باللغة العربية.
- لا يزيد البحث عن ١٥٠ صفحة، ويجوز لمجلس الإدارة استثناء البحوث الممتازة من هذا الشرط.
- يشترط ألا يكون العمل المقدم قد سبق نشره أو قدم للنشر في أية جهة أخرى.
- يقدم البحث في صورته الأخيرة المقبولة للنشر من ثلاث نسخ مرفقاً به اسطوانة ليزر (CD) مستخدماً إحدى برمجيات معالجة النصوص مع نظام ويندوز المتوافق مع IBM، على أن تكون الكتابة ببنط ١٤ ومسافة ١ بين الأسطر، وتقدم الخرائط والصور والأشكال مستقلة محفوظة في صورة JPEG أو Tiff و Resolution ٢٠٠ فأكثر.
- يفضل أن تقدم الخرائط والأشكال البيانية بالألوان بحيث لا تتجاوز مساحتها (١٢سم عرض × ١٨سم طول)، وإن تعذر ذلك تقدم بالأبيض والأسود وفق القواعد الكارتوجرافية.
- يكتب الباحث اسمه واسم البحث في ورقة منفصلة ويكتفى بكتابة عنوان البحث فقط على رأس البحث مراعاة لسرية التحكيم.
- يعرض البحث على اثنين من المحكمين من كبار الأساتذة في مجال التخصص، وفي حالة اختلاف رأى المحكمين، يرسل البحث إلى محكم ثالث، مرجح، وبناء على تقاريرهم يمكن قبول البحث للنشر أو إعادته للباحث لإجراء التعديلات أو التصويبات الضرورية قبل نشره.
- البحوث التي تقدم للنشر لا ترد إلى مقدميها سواء نشرت أو لم تنشر.
- تحتفظ الجمعية بحقوق النشر كاملة.
- يسلم للباحث ١٠ نسخ من بحثه بعد نشره، وإذا أراد نسخاً إضافية يسدد ثمنها طبقاً

هيئة تحرير المجلة

أ.د. محمد زكي السديمي	رئيس مجلس إدارة المجلة
أ.د. إسماعيل يوسف إسماعيل	نائب رئيس مجلس إدارة المجلة ورئيس التحرير
أ.د. مصطفى محمد البغدادي	مدير التحرير
أ.م. د. محمد إبراهيم خطاب	محرر تنفيذي
أ.م. د. كامل مصطفى كامل	محرر تنفيذي
د. محمد ربيع عبد الظاهر	محرر تنفيذي
د. رشا حسين رمضان	محرر تنفيذي
د. بشير الشوربجي	مدقق لغوي

مجلس إدارة الجمعية الجغرافية المصرية

أ.د. محمد زكي السديمي	رئيس مجلس إدارة الجمعية
أ.د. عبد الله علام عبده علام	نائب رئيس مجلس إدارة الجمعية
أ.د. إسماعيل يوسف إسماعيل	أمين عام الجمعية
أ.د. مسعد السيد أحمد بحيري	أمين صندوق الجمعية
أ.د. فتحي محمد أبو عيانة	عضو مجلس إدارة الجمعية
أ.د. أحمد حسن إبراهيم	عضو مجلس إدارة الجمعية
أ.د. أحمد السيد الزاملى	عضو مجلس إدارة الجمعية
أ.د. شحاتة سيد أحمد طلبة	عضو مجلس إدارة الجمعية
أ.د. مصطفى محمد البغدادي	عضو مجلس إدارة الجمعية
أ.د. عبد العظيم أحمد عبد العظيم	عضو مجلس إدارة الجمعية
أ.د. عمر محمد علي محمد	عضو مجلس إدارة الجمعية
أ.د. سامح إبراهيم عبد الوهاب	عضو مجلس إدارة الجمعية
أ.د. عادل عبد المنعم السعدني	عضو مجلس إدارة الجمعية
أ.د. عطية محمود الطنطاوي	عضو مجلس إدارة الجمعية
أ.د. عبير ابراهيم عبد الله	عضو مجلس إدارة الجمعية

الهيئة الاستشارية

أ.د. عبد الله يوسف الغنيم	أستاذ الجغرافيا الطبيعية بمركز البحوث والدراسات الكويتية
أ.د. نبيل سيد امبابي	أستاذ بقسم الجغرافيا كلية الآداب جامعة عين شمس
أ.د. فتحي عبد العزيز أبو راضي	أستاذ بقسم الجغرافيا كلية الآداب جامعة الاسكندرية
أ.د. فاروق كامل عز الدين	أستاذ بقسم الجغرافيا كلية الآداب جامعة الزقازيق
أ.د. سعيد محمد عبده	أستاذ بقسم الجغرافيا كلية البنات جامعة عين شمس
أ.د. محمد عبد الرحمن الشرنوبي	أستاذ بقسم الجغرافيا كلية الآداب جامعة الفيوم
أ.د. السعيد إبراهيم البدوي	أستاذ بقسم الجغرافيا كلية الدراسات الأفريقية العليا جامعة القاهرة
أ.د. جودة فتحي التركماني	أستاذ بقسم الجغرافيا كلية الآداب جامعة القاهرة
أ.د. كريم مصلح صالح	أستاذ بقسم الجغرافيا كلية الآداب جامعة سوهاج
أ.د. محمد نور الدين السبعاوي	أستاذ بقسم الجغرافيا كلية الآداب جامعة المنيا
أ.د. عزة أحمد عبد الله	أستاذ بقسم الجغرافيا كلية الآداب جامعة بنها
أ.د. مسعد سلامة مندور	أستاذ بقسم الجغرافيا كلية الآداب جامعة المنصورة
أ.د. إبراهيم محمد علي بدوي	أستاذ بقسم الجغرافيا كلية الآداب جامعة دمياط
أ.د. إبراهيم علي عبد الهادي غانم	أستاذ بقسم الجغرافيا كلية الآداب جامعة طنطا
أ.د. محمد فوزي عطا	أستاذ بقسم الجغرافيا كلية الآداب جامعة بني سويف
أ.د. ايملي محمد حلمي حمادة	أستاذ بقسم الجغرافيا كلية الآداب جامعة المنوفية
أ.م. د. علي الدوسري	أستاذ مساعد بقسم الجغرافيا – جامعة الملك سعود – السعودية
Dr. Niki Evelpidou	**National & Kapodistrian University of Athens Faculty of Geology and Geoenvironment, Greece**

فهرس المحتويات

م	العنوان	ص
	المُلخص	١
	١. المقدمة	٢
	٢. أهداف الدراسة	٤
	٣. أهمية موضوع البحث	٤
	٤. الدراسات السابقة	٤
	٥. مواد البحث النظرية	١٣ – ٢٢
	٦. منطقة الدراسة	٢٢
	٧. المنهجية العامة للبحث	٢٣ – ٣٩
	٨. النتائج والمناقشة	٣٩ – ٦٢
	٩. الاستنتاجات والتوصيات	٦٢
	١٠. المراجع	٦٣ – ٦٦
	المُلخص باللغة الإنجليزية	٦٧

فهرس الأشكال

م	العنوان	ص
١	منطقة الدراسة	٢٣
٢	المنهجية العامة للبحث	٢٣
٣	مجموعة بيانات الليدار والملفات ضمنها	٢٥
٤	التغطية المكانية لبيانات الليدار لمنطقة الدراسة	٢٦
٥	جزء من غمامة نقاط الليدار في منطقة الدراسة	٢٦
٦	معلمات تحويل مجموعة بيانات الليدار الى سطح DSM	٢٨
٧	فئات تصنيف نقاط السحابة في ArcGIS Pro	٢٩
٨	عينة من نقاط الليدار المصنفة كمباني لاستخراج بصمات المباني	٣٢
٩	عينة من طبقة raster تظهر مواقع نقاط المباني	٣٢
١٠	عينة من طبقة مضلعات المباني الأولية	٣٣

١١	سـير عمل معالجة المضـلعات للحصـول على طبقة بصـمات المباني النهائية	٣٣
١٢	سطح أحد المباني من طبقة قيم شدة LiDAR قبل وبعد تطبيق مرشح المتوسط (mean filter)	٣٥
١٣	التوزيع المكاني للعينات المرجعية الأرضـية (عينات التصـنيف والاختبار)	٣٦
١٤	سـير عمل معالجة بيانات الليدار لاسـتخلاص أسـطح المباني وأنواعها في بيئة GIS	٣٦
١٥	التجزئة (معامل المقياس = ٤٠، الشـكل = ٠.٢، الاكتناز = ٠.٥) لجزء من منطقة الدراسة باستخدام بيانات الليدار	٣٧
١٦	مخطط قواعد القرار لاسـتخلاص أسـطح المباني من بيانات الليدار	٣٨
١٧	منهجية العمل للتصنيف الهدفي لبيانات الليدار	٣٩
١٨	النموذج الرقمي للسطح (DSM) لمنطقة الدراسة	٤٠
١٩	خريطة الانحدار Slope لمنطقة الدراسة	٤١
٢٠	خريطة الاتجاه Aspect لمنطقة الدراسة	٤١
٢١	جزء من سحابة النقاط LiDAR المصنفة كأرض طبيعية	٤٢
٢٢	نموذج DTM لمنطقة الدراسة	٤٣
٢٣	عينة من نقاط الليدار الشاذة في منطقة الدراسة	٤٣
٢٤	عينة من نقاط الليدار المصنفة كنقاط مباني	٤٤
٢٥	طبقة raster تظهر مواقع نقاط المباني	٤٤
٢٦	طبقة مضلعات أسطح المباني في منطقة الدراسة	٤٥
٢٧	سطح قيم شدة بيانات الليدار في منطقة الدراسة	٤٦
٢٨	تصـنيف أسطح المباني إلى ثلاثة أصـناف رئيسـية بناءً على قيم شدة انعكاسية بيانات ليدار في بيئة GIS	٤٧
٢٩	متوسط شدة انعكاسية بيانات الليدار لعينات التصنيف	٤٨
٣٠	أنواع الأسطح في منطقة الدراسة حسب قيم شدة بيانات الليدار في بيئة GIS	٤٩

٣١	مقارنة بصـــرية بين طبقة بصـــمات المباني الناتجة مع تلك الموجودة في المرئية الفضائية (a) وفي خريطة الأساس العالمية (b)	٥٠
٣٢	عينات مباني الاختبار لتقييم دقة تجزئة غمامة الليدار	٥٠
٣٣	اختلاف في الطوبولوجيا بين البيانات المرجعية والنتيجة المصنفة	٥٣
٣٤	طبقة أسطح المباني التي تم استخلاصها من التصنيف الهدفي لبيانات الليدار	٥٥
٣٥	التصنيف الهدفي لأنواع الاسطح من بيانات الليدار باستخدام خوارزمية SVM	٥٦
٣٦	التصنيف الهدفي لأنواع الاسطح من بيانات الليدار باستخدام خوارزمية RT	٥٦
٣٧	التصنيف الهدفي لأنواع الاسطح من بيانات الليدار باستخدام خوارزمية DT	٥٧
٣٨	اختلاف في الطوبولوجيا بين البيانات المرجعية والنتيجة المصنفة هدفيا	٥٧
٣٩	مقارنة دقة استخراج أسطح المباني من بيانات الليدار في بيئة GIS والتصنيف الهدفي	٥٨
٤٠	مقارنة نتائج خوارزميات SVM RT وDT والتصنيف باستخدام أدوات GIS. لتصنيف أنواع الاسطح من بيانات الليدار	٦١
٤١		

فهرس الجداول

م	العنوان	ص
١	ملفات بيانات الليدار المتوفرة لمنطقة الدراسة مع بعض الإحصائيات	٢٤
٢	نتائج تقييم دقة تجزئة غمامة الليدار	٥١
٣	نتائج تحليل دقة استخلاص أسطح المباني من غمامة الليدار	٥٣
٤	مصفوفة الخطأ لتقييم تصنيف أنواع أسطح المباني باستخدام بيانات شدة LiDAR وأدوات GIS	٥٤

٥	إحصائيات طبقة أسطح المباني التي تم استخلاصها من التصنيف الهدفي لبيانات الليدار	٥٥
٦	نتائج تحليل دقة التصنيف الهدفي لاستخلاص أسطح المباني من بيانات الليدار	٥٨
٧	مصفوفة الخطأ لتقييم تصنيف أنواع أسطح المباني باستخدام بيانات شدة LiDAR وخوارزمية SVM	٥٩
٨	مصفوفة الخطأ لتقييم تصنيف أنواع أسطح المباني باستخدام بيانات شدة LiDAR وخوارزمية RT	٦٠
٩	مصفوفة الخطأ لتقييم تصنيف أنواع أسطح المباني باستخدام بيانات شدة LiDAR وخوارزمية DT	٦٠

استخلاص أسطح المباني وأنواعها من بيانات الليدار باستخدام التقنيات الجيومكانية والتصنيف الهدفي لمجموعة من أحياء مدينة الرياض

المُلخص:

يهدف هذا البحث إلى مقارنة دقة نهجين مختلفين لاستخلاص أسطح المباني وأنواعها من بيانات LiDAR في مدينة الرياض، المملكة العربية السعودية. النهج الأول يعتمد على معالجة البيانات في بيئة نظم المعلومات الجغرافية (GIS)، بينما يعتمد النهج الثاني على التصنيف الهدفي.

في النهج الأول، تم استخدام بيانات LiDAR لعام ٢٠١٢ لإنشاء نموذج رقمي للسطح (DSM) وخرائط الانحدار slope والاتجاه aspect وقيم شدة الانعكاس Intensity. تم تصنيف نقاط LiDAR إلى ثلاث فئات: أرض، ضوضاء، ومبانٍ. بعد ذلك، تم استخراج بصمات المباني ثنائية الأبعاد وتصنيف أنواع الأسطح بناء على قيم شدة الانعكاس.

أما النهج الثاني، فقد اعتمد على بيانات nDSM، Intensity، slope، وaspect (وهي مشتقة من بيانات الليدار نفسها). تم تطبيق تقنية تجزئة multiresolution لتصنيف الصور إلى فئتين: أسطح المباني والخلفية باستخدام قواعد القرار. ثم تم استخدام ثلاث خوارزميات تصنيف – آلة ناقل الدعم (SVM)، وشجرة القرار (DT)، والشجرة العشوائية (RT) – لتصنيف أنواع الأسطح إلى ست فئات: أسطح ذات صبة جاهزة مع بحص (ملساء وخشنة)، أسطح ذات أسمنت عادي (مبانٍ ومواقف)، أسطح مبلطة، وباقي الأسطح.

أظهرت النتائج أن أدوات GIS حققت دقة إجمالية ٨٨٪ في استخراج أسطح المباني، بينما حقق التصنيف الهدفي دقة ٨٤.٤٪. يرجع التفوق الطفيف لأدوات GIS إلى الدقة المكانية العالية لإحداثيات نقاط بيانات LiDAR. في المقابل، تفوقت خوارزميات التصنيف الهدفي في تصنيف أنواع الأسطح، حيث حققت خوارزمية RT أعلى دقة إجمالية (٦٧٪) ومقياس Kappa (٠,٤٩). يرجع انخفاض دقة تصنيف أنواع الأسطح بشكل عام ذلك إلى تداخل قيم شدة LiDAR بين بعض أنواع الأسطح.

بشكل عام، كلا النهجين فعالان في استخلاص أسطح المباني، مع تفوق طفيف لأدوات GIS. ومع ذلك، تظهر خوارزميات التصنيف الهدفي دقة أفضل في تصنيف أنواع الأسطح. يوصى بدمج بيانات LiDAR مع صور فضائية عالية الدقة لتحسين دقة التصنيف والتغلب على قيود كلا النهجين. كما

يوصى بإجراء المزيد من الأبحاث لتطوير تقنيات تصنيف أكثر تقدماً ودراسة تأثير عوامل أخرى على دقة التصنيف، مثل خصائص المباني والبيئة المحيطة.

الكلمات المفتاحية: بيانات LiDAR، أسطح المباني، أنواع الأسطح، نظم المعلومات الجغرافية، التصنيف الهدفي، الرياض.

(المجلة الجغرافية العربية، المجلد (٥٥)، العدد (١٩٥) عدد خاص، يونيو ٢٠٢٤، ص ص ١ – ٦٧)

١. المقدمة:

يعيش أكثر من نصف سكان العالم في مناطق حضرية معقدة تواجه عدد من التحديات المرتبطة بإدارة المناطق الحضرية سواء من حيث نطاقها أو مدى تعقيدها. كما تشير التقديرات إلى أن ٧ من كل ١٠ أشخاص سيسكنون في المناطق الحضرية بحلول عام ٢٠٥٠ (UN-HABITAT, 2012). ولذلك يؤدي النمو الحضري المخطط له بشكل جيد إلى تحسين الاستفادة من الخدمات المتعلقة بالتعليم والصحة والسكن والخدمات الأخرى وتوسيع فرص الإنتاجية الاقتصادية وتحسين إدارة الأثر الذي يخلفه الإنسان على (الأمم المتحدة – إدارة الشؤون الاقتصادية والاجتماعية، ٢٠١٤). فالنمو الحضري السريع يطرح تحديات امام التخطيط الحضري المستدام منها أسطح المباني التي تشكل ما يقارب ٢٠ إلى ٢٥٪ من البيئة الحضرية (Rose et al., 2003). والمكونة من مواد مختلفة سواء اصطناعية أو طبيعية والتي من شأنها أن تؤثر على البيئة (Taherzadeh & Shafri, 2013).

المباني هي عناصر هامة في نمذجة المعلومات الحضرية City Information Modeling (CIM) (J. Wang et al., 2024). كما تقدم أسطح المباني إمكانات كبيرة في معالجة مشكلات التحضر الرئيسية مثل تحليل الملاءمة، وإدارة الكوارث، وغيرها (Adeleke & Smit, 2020).

تشهد تقنية الليدار تزايداً ملحوظاً في جمع البيانات الحضرية ثلاثية الأبعاد، وهو ما يفتح أفقاً جديداً لفهم تطورات المدن وتأثيراتها على البيئة، بما في ذلك الكثافة السكانية واستهلاك الطاقة. ورغم هذا التطور، يظل توفير خرائط ارتفاع المباني ذات دقة عالية تحديا (Ma et al., 2023)، حيث تكون هذه المعلومات الرأسية حاسمة لتحليل المناطق الحضرية بشكل فعّال. تعتبر بيانات الليدار، المتاحة حديثا مفتاحا لتحقيق هذا الهدف، إذ تتيح للباحثين والمختصين استخدامها في استخلاص أسطح المباني بطرق دقيقة وفعّالة. هذا التقدم في استخدام بيانات الليدار يعزز إمكانيات فهمنا للمدن الحديثة ويسهم في

تحسين التخطيط الحضري والاستدامة البيئية. حيث يعد الليدار أداة ممتازة لقياس ارتفاع المباني وقد تم استخدامه بشكل متكرر كمصدر لبيانات مرجعية للتحقق من ارتفاعات المباني المستخلصة من الصور.

يتم استخلاص أسطح المباني أو بصمات المباني بدقة عالية من بيانات الليدار ويتم استخدامها على نطاق واسع في إعادة بناء نماذج المباني ثلاثية الأبعاد عالية الدقة كتعبير عن ثلاثي الأبعاد في عملية الرقمنة للعالم الحقيقي، يمكن لبيانات سحابة النقاط الاحتفاظ بالهيكل الهندسي الأصلي لبيانات المسح بطريقة مدمجة ومرنة (J. Wang et al., 2024). ولذلك يعد انشاء اشكال هندسية للأسطح باستخدام LiDAR حل مناسب لاستخراج كل من الارتفاع والاتجاه والانحدار (Tooke, 2013).

كما يمكن الاستفادة من قيمة الانعكاس المتوفرة في بيانات الليدار في تحديد أنواع أسطح المباني نظرا لان هذه القيمة مرتبطة بنوع المادة التي يتكون منها سطح البناء. حيث تعد بيانات LiDAR ذات أهمية كبيرة في تحديد ارتفاع الاسطح بشكل دقيق، كون ان بعض أسطح المباني تتكون من بلاط مماثل لما هو موجود في أرضية الفناء الخارجي الأرضي للمبنى، وقد يصعب التفرقة بين الاسطح والارض؛ فلذلك تعد بيانات LiDAR مساهمة بشكل فعال في تحديد الارتفاع الذي يمكن من خلاله التفرقة بين سطح المبنى وارضية الفناء الخارجي.

هناك تطورات كبيرة في مجال الخوارزميات والتقنيات المتعلقة باستخراج أسطح المباني من سحابة بيانات الليدار. كما توجد طرق ومنهجيات متعدد لا نجاز ذلك. من هذه المنهجيات استخلاص أسطح المباني وأنواعها من بيانات LiDAR باستخدام بيئة GIS والتي تم استخدامها من قبل العديد من الباحثين مثل (Gergelova et al., 2020; Margolis et al., 2017; Rutzinger et al., 2006)، ومنهجية التصنيف الهدفي Object-Based Classification، حيث ظهر دور التصنيف الهدفي من قبل عدد من الباحثين لاستخراج المباني ونوعية اسطحها وذلك لأهداف وأسباب مختلفة (Attarzadeh & Momeni, 2018; Norman et al., 2020; الجعيدي & المثيبي، ٢٠٢١).

ركزت هذه الدراسة على استخدام التقنيات الجيومكانية لمعالجة واستخلاص أسطح المباني وأنواعها من سحابة بيانات الليدار الجوي في منطقة الدراسة (الرياض، المملكة العربية السعودية) بالمنهجيتين السابقتين. يهدف ذلك إلى تمكين المستخدم النهائي من الحصول بسهولة على معلومات أولية حول أسطح المباني، مثل الحدود، والشكل الهندسي، والارتفاعات وأنواعها.

٢. أهداف الدراسة:

يهدف هذا البحث بشكل أساسي إلى استخدام نهجين مختلفين لاستخلاص أسطح المباني وأنواعها من بيانات LiDAR في منطقة حضرية ومقارنة دقتهم. ويمكن تحقيق هذا الهدف من خلال الأهداف الجزئية التالية:

- استخلاص أسطح المباني وأنواعها من بيانات LiDAR باستخدام بيئة GIS.
- استخلاص أسطح المباني وأنواعها من بيانات LiDAR باستخدام التصنيف الهدفي مع تطبيق ثلاثة خوارزميات مختلفة (SVM و DT و RT) لتصنيف أنواع الأسطح من بيانات LiDAR.
- مقارنة دقة كل نهج في استخلاص أسطح المباني وتحديد أنواعها.

٣. أهمية موضوع البحث:

تأتي أهمية البحث من كون استخراج أسطح البناء وأنواعها باستخدام بيانات ليدار الجوي حظي باهتمام كبير في السنوات الأخيرة بسبب تطبيقاته المحتملة في مجالات مختلفة، بما في ذلك التخطيط العمراني، والرصد البيئي، وإدارة الكوارث. كما أن تحديد أسطح المباني مفيد بشكل أساسي لفهم إمكانات الطاقة الكهروضوئية (PV) للمناطق الحضرية ونماذج معلومات البناء BIM وإدارة البلديات. ومع تزايد المناطق الحضرية بشكل مطرد والحاجة إلى ممارسات الطاقة المستدامة، فإن التقنيات الموثوقة والفعالة من حيث التكلفة لتحديد أسطح المباني تعد بالتالي متطلبا مفيدا.

٤. الدراسات السابقة:

لقد حظي استخراج أسطح البناء باستخدام بيانات ليدار الجوي (Airborne LiDAR) باهتمام كبير في السنوات الأخيرة بسبب تطبيقاته المحتملة في مجالات مختلفة، بما في ذلك التخطيط العمراني، والرصد البيئي، وإدارة الكوارث. تحديد أسطح المباني مفيد بشكل أساسي لفهم إمكانات الطاقة الكهروضوئية (PV) للمناطق الحضرية ونماذج معلومات البناء BIM وإدارة البلديات. ومع تزايد المناطق الحضرية بشكل مطرد والحاجة إلى ممارسات الطاقة المستدامة، فإن التقنيات الموثوقة والفعالة من حيث التكلفة لتحديد أسطح المباني تعد بالتالي متطلبًا مفيدًا.

تتمثل إحدى المزايا الرئيسية لاستخدام بيانات ليدار الجوي لاستخراج أسطح البناء في قدرته على توفير معلومات ثلاثية الأبعاد دقيقة للغاية ومفصلة حول البيئة المبنية (Kushwaha et al., 2019).

ويمكن لبيانات ليدار الجوي التقاط التفاصيل الهندسية لأسطح البناء بدقة عالية، مما يسمح بالتعرف الدقيق على حدود المبنى ورسمها.

علاوة على ذلك، يوفر استخدام بيانات ليدار الجوي لاستخراج أسطح البناء مزايا واضحة على مصادر بيانات الاستشعار عن بعد الأخرى. على سبيل المثال، مقارنة بالتصوير الجوي، يمكن لبيانات ليدار الجوي تقديم تمثيل أكثر شمولاً وتفصيلاً للمباني. يعود هذا بشكل أساسي إلى الكثافة والدقة العالية لبيانات سحابة نقاط ليدار. كما يمكن لبيانات ليدار الجوي التقاط انعكاس متعددة لنقاط كائنات ثلاثية الأبعاد، مما يسمح بالنمذجة الدقيقة للهياكل المعقدة للمباني والتقاط المعلومات الرأسية لأسطح البناء.

يعد استخراج أسطح البناء باستخدام بيانات ليدار الجوي عملية معقدة تتضمن طرقا حسابية مختلفة. أحد الأساليب الشائعة هو تقسيم سحابة نقاط ليدار إلى كائنات فردية، يليها استخراج نقاط سطح البناء بناءً على معايير معينة مثل كثافة النقاط وعتبات الارتفاع.

لقد تم استخدام نظام تحديد المدى بالليزر المحمول جواً لتحديد أشكال مختلفة من الأسطح بسبب التفاصيل الهندسية الموجودة في سحابة النقاط ثلاثية الأبعاد التي تم الحصول عليها باستخدام هذه المنصة (Jung et al., 2017; Kushwaha et al., 2019).

يوجد العديد من الدراسات التي قامت بتنفيذ طرق مختلفة لاستكشاف واستخراج الأسطح من بيانات LiDAR نذكر منها:

• دراسة (Wang et al., 2024):

قدم الباحثون في هذه الدراسة خوارزمية مبتكرة لاستخراج خطوط الـ contour من سحابات نقاط LiDAR. في نهجهم، تم استخدام النطاقات متعددة الاتجاهات لتحديد نقاط خطوط الـ contour الأولية، التي يتم فرزها وتوصيلها وتكثيفها بدقة. يؤدي هذا الإجراء إلى استخراج خطوط الـ contour الخارجية عالية الجودة مع علاقات طوبولوجية جيدة التحديد. تظهر الخوارزمية متانة جيدة، خاصة عند التعامل مع سحب النقاط ذات الكثافات المتنوعة، مما يبرز تنوعها. تم تصميم الخوارزمية بمعلمات قابلة للتعديل بسهولة، مما يعزز قابليتها للتكيف وضمان كفاءة استخراج عالية لإعادة بناء نماذج المباني ثلاثية الأبعاد.

• دراسة (Fareed et al., 2023):

تم في هذا البحث استكشاف خوارزميات تصنيف الأرض التقليدية بجانب أساليب التعلم الآلي الحديثة لفصل نقاط الأرض من بيانات UAS-LiDAR عالية الكثافة (حوالي ٩٠٠ نقطة/متر مربع)، حيث تم تنفيذ الدراسة على خمسة حقول زراعية في نورث داكوتا، الولايات المتحدة. تم اختبار عدة خوارزميات من بينها فلتر محاكاة القماش (CSF)، وفلتر التشكل التقدمي (PMF)، وتصنيف الانحناء متعدد المقاييس (MCC)، بالإضافة إلى تقنيات تصنيف الأرض في برنامج ArcGIS ونموذج التعلم العميق Point CNN. أشار الباحثون إلى أن خوارزميات تصنيف نقاط الأرض في برنامج ArcGIS تأتي مع معلمات اختيارية افتراضية مثل إعادة استخدام نقاط الأرض الموجودة أثناء تصنيف الأرض، مما يوفر مزيدا من الأتمتة ولكن مع قليل من التحكم في عملية التصنيف. وبالتالي، فإن معالجة سحابة النقاط باستخدام ArcGIS هي عبارة عن حل شامل بصندوق أسود مع صيغة رياضية أساسية غير معروفة.

تتمحور دراستنا ليس فقط حول تصنيف النقاط الأرضية، بل أيضاً حول تصنيف نقاط المباني، وسيتم الاستفادة من هذه الدراسة في الاطلاع على أداء الخوارزميات المختلفة في تصنيف النقاط الأرضية وغير الأرضية وطريقة تقييم الدقة.

• دراسة (Gergelova et al., 2020):

قدم البحث إجراءً شاملا باستخدام أدوات (GIS) لتحديد أسطح المباني باستخدام بيانات سحابة النقاط LiDAR بكثافة متوسطة تبلغ ١٩ نقطة في المتر المربع. مع التركيز على إنشاء حدود سطح المبنى وعرض التحليلات المكانية، كان هدف الطريقة تقييم الإمكانيات المحتملة لدمج أنظمة الطاقة الشمسية والأسطح الخضراء في مباني المدن الذكية. قدم البحث إجراءات معالجة في بيئة GIS لتحديد أسطح المباني باستخدام بيانات سحابة النقاط LiDAR. تم إنشاء حدود لأسطح البناء بشكل مبسط ومنتظم. تم اختيار ستة أنواع مختلفة من الأسطح من بين ٨٢٤ سطحا في المنطقة المدروسة. تم التعامل مع التحديات مثل التصنيف غير المناسب للنقاط وكثافة النقاط غير الكافية، مما يؤدي إلى وجود فجوات داخل مناطق السطح. شملت الدراسة أيضًا عرض التحليلات المكانية المتعلقة بالأسطح المحددة، مما يوفر رؤى قيمة لتخطيط المدن وتطوير البنية التحتية المستدامة.

تم استخدام برنامج ArcGIS Pro في الدراسة لعملية تقسيم أسطح المباني وإجراءات تبسيط المباني وتنظيم المباني لتجميع وتنظيم مناطق السطح. توصي المقالة باستخدام كثافة نقاط سحابة أعلى إذا تتطلب الأمر تفاصيل دقيقة أكثر للأسطح. استدعت عملية التقسيم مقاربة فردية بسبب تنوع أنواع الأسطح، واختارت الدراسة ستة أسطح أساسية للتحليل. سيسهل توفر بيانات حول نوع السطح وقطاعاته في أنظمة المعلومات الحكومية عملية تقسيم السطح تلقائيًا بشكل كبير.

تتميز دراستنا عن هذه الدراسة في أننا نركز على تجزئة أسطح المباني المستوية في منطقة الدراسة. سنستفيد من جزء من المنهجية المقترحة في هذه الدراسة لتجزئة نقاط السحابة، لكننا سنستخدم أدوات معالجة مختلفة لتحسين دقة تحديد حدود المباني. تهدف هذه الأدوات إلى تجاوز قيود تقنية تقسيم مستجمعات المياه القائمة على الخطوط والمناطق، والتي لا تُظهر نتائج جيدة مع أسطح المباني المستوية.

• دراسة (Adelek & Smit, 2020):

هدفت هذا الدراسة إلى بيان الطرق التي يمكن من خلالها استغلال تقنيات الاستشعار من بعد لتحديد مواقع أسطح المباني واستخلاصها لإجراء تحليلات متعددة الأغراض، كالتحليل لإمكانية استخدام الطاقة الشمسية وتجميع مياه الأمطار. وقد تم تطوير تقنية متميزة تجمع بين كشف أسطح المباني واستخراج معالمها. تم تطبيق هذه الطريقة في مدينة كيب تاون بجنوب أفريقيا (٢٤٦١ كم٢) كمثال عملي، حيث تم استخلاص أسطح المباني بالاعتماد على مزج بيانات LiDAR مع المرئيات الفضائية ضمن إطار عملية التصنيف الهدفي. وقد أفضى ذلك إلى إنشاء قائمة بأسطح المباني تضم خصائص هامة لتقييم أسطح المباني لأغراض تحليلات الملاءمة المتنوعة. وقد أظهرت الطريقة المبتكرة فعالية خاصة في المناطق السكنية والصناعية التي تتميز بسهولة فصل المباني عن بعضها.

أشارت نتائج تقييم الدقة التي تم الحصول عليها إلى نجاح المنهجية المطورة في الكشف عن أسطح المباني واستخراجها. تعمل تقنية الاستخراج بكفاءة أعلى في الأحياء السكنية حيث يسهل تمييز المباني عن بعضها، بخلاف المناطق التجارية المركزية التي تتصل فيها المباني بشكل متقارب. ويمكن تحقيق دقة أعلى في الكشف والاستخراج باستخدام بيانات نقطية لـ LiDAR أكثر كثافة، ولكن ذلك قد يتطلب المزيد من الوقت والمساحة لمعالجة وتخزين البيانات.

كما اشارت الدراسة الى أن الخصائص الطيفية للمرئيات الفضائية لعبت دورا محوريا عند دمجها مع بيانات LiDAR، حيث ساهمت في تقسيم المشهد بطريقة تحليلية وفي تحديد عناصر معينة مثل أغطية الأشجار والمناطق المظللة. كما أسهمت خصائص الميل والارتفاع والاتجاه المستخلصة من منتجات LiDAR في الكشف عن تراكيب أسطح المباني وتقسيمها إلى مستويات مختلفة.

سيتم الاستفادة من هذه الدراسة من أساليب معالجة بيانات LiDAR. بالإضافة إلى ذلك، سيتم الاستفادة من بعض المنهجيات المستخدمة في الدراسة السابقة واختبار دقتها.

• دراسة (Xue et al., 2020):

تطرقت هذه الدراسة إلى مقاربة للتحسين الدلالي لنماذج معلومات المدينة بقيمة الالبيدو (Albedo) القائم على LiDAR لنماذج الأسطح. اعتمدت الدراسة طريقة (Chen et al., 2018) لإعادة بناء الأشكال الهندسية لعناصر الأسطح. بعد ذلك، يتم تقدير قيمة الالبيدو للأسطح وعناصر الأسطح من متوسط الانعكاس في بيانات LiDAR. أجريت الدراسة التجريبية في منطقة حضرية في هونغ كونغ. أظهرت النتائج أن نماذج البناء التي تم إنشاؤها بواسطة النهج المقدم كانت جيدة من حيث عناصر الأسطح والألبيدو. ركزت هذه الدراسة على التعامل مع LiDAR وأوضحت طريقة (Ke Chen، 2018).

• دراسة Invalid source specified:

تطرقت هذه الدراسة إلى ان التكلفة والوقت والجهد المبذول في استخلاص المباني في المناطق الحضرية بالطرق والأساليب التقليدية المتمثلة في المسح الميداني أو التحليل البصري للصور الجوية والمرئيات الفضائية أو التحليل التقني المعتمد على الخلية، من التحديات التي تواجه الكارتوغرافيين، خاصة في المناطق الحضرية الكبيرة والتي تشهد تطورا سريعا. استخدمت الدراسة أسلوب التصنيف الهدفي Object-Based Classification في استخلاص المباني من المرئيات الفضائية ذات الوضوح المكاني العالي للقمر الصناعي WorldView-3 (WV3)، ومقارنتها مع طرق التصنيف التقليدية المعتمدة على الخلية Pixel. وطبقت الدراسة على جزيرة تاروت شرق المملكة العربية السعودية. وتم استخلاص المباني باستخدام مصنفي الجار الأقرب Nearest Neighbor وقواعد القرار Decision Rules. وقيمت صحة نتائج التصنيف وذلك باستخدام عدد من المقارنات الإحصائية للنتائج مع التصنيفات التقليدية المبنية على الخلية، وشملت مصنفات آيزوداتا IsoData، ومتوسطات–ك K-means في التصنيف غير المراقب Unsupervised Classification والاحتمالات العظمى Maximum Likelihood Classifier

والمسافة الدنيا للمتوسطات Minimum Distance to Means Classifier والانابيب المتوازية Parallelepiped Classifier في التصنيف المراقب Supervised Classification. وتم انتاج خرائط موضوعية باستخدام جميع الطرق السابقة وتم تقييم جودتها وذلك باستخدام اختبار الصحة الشاملة Overall Accuracy ومعامل كابا Kappa Coefficient. وتوصلت إلى ان الأساليب المستخدمة حققت صحة عالية في استخلاص المباني في المناطق الحضرية وتفوقت على الأساليب التقليدية. وأوصت الدراسة إلى ضرورة تطوير نماذج مساعدة في تحسين التصنيف في بيئة التصنيف الهدفي.

كما أن هذه الدراسة شملت قيود وهي عدم توفر بيانات الارتفاعات للمباني مثل بيانات Lidar أو بيانات Digital Surface Model (DSM). تتوافق هذه الدراسة مع دراستنا في تحديد وتصنيف المباني ولذلك باتباع جزء من المنهجيات التي توصلت اليها هذه الدراسة والخاصة بالتصنيف الهدفي ولكن سنطبقها على بيانات الليدار. حيث سيتم استخدام بيانات Lidar وهو ما أوصت به هذه الدراسة

- دراسة (Kushwaha et al., 2019):

في البحث الذي أجراه Kushwaha et al عام ٢٠١٩، ركز الاهتمام الأساسي على عملية تقسيم سحابة النقاط المعقدة، ولا سيما معالجة تنظيم سحابة نقاط غير محددة. شمل البحث إنشاء سحابة نقاط RGB من خلال الاستفادة من الصور التي تم الحصول عليها من طائرة بدون طيار (UAV) في بيئة حضرية كثيفة تتميز بميزات مستوية متنوعة داخل البيئة المبنية وصغيرة المساحة، والتي تشمل هياكل بمستويات مختلفة. في البداية، خضعت بيانات سحابة النقاط (PCD) لعملية تقسيم باستخدام مرشح Cloth Simulation Filter (CSF)، حيث تم التمييز بين ميزات الأرض وغير الأرض. وشملت الفئة الأخيرة الأشجار والمباني، بينما تضمنت الفئة الأولى الطرق والنباتات الأرضية والأراضي المفتوحة. تم تحقيق التحسين الإضافي من خلال تطبيق مصنف CANUPO، وتحديد نقاط الأشجار والمباني بشكل خاص. تضمن التحقق من صحة منهجية التقسيم مقارنة دقيقة مع نقاط السطح التي تم تحديدها يدويًا في سحابة النقاط، مما أدى إلى دقة شاملة جيدة جدا بلغت ٩٠,٨٦٪ .

في دراستنا سنستخدم غمامة نقاط الليدار الجوي وليس نقاط سحابة ناتجة عن الصور التي تم الحصول عليها من طائرة بدون طيار (UAV)، غير أنه سيتم الاستفادة من معادلات تقييم دقة تجزئة نقاط السحابة.

• دراسة (محسن & الشرفاء، ٢٠١٩):

تناولت هذه الدراسة الحد الأعلى لأنظمة الطاقة الشمسية الكهروضوئية الموزعة التي يمكن تركيبها في مدينة الرياض باستخدام نظم المعلومات الجغرافية. وتوصل الباحثون إلى انه يُفضَّل استخدام صور جوية عالية الدقة أو بيانات LiDAR لتحديد وقياس مساحة الأسطح المناسبة الملبية لمتطلبات تركيب الطاقة الشمسية الكهروضوئية؛ إلا أن هذه البيانات (الصور الجوية عالية الدقة أو بيانات LiDAR) ليست موجودة في هذه الدراسة. لهذا تستند هذه الدراسة إلى إحصاءات قطع الأراضي على النحو المحدد في مجموعات بيانات استخدام قطع الأراضي وتقسيماتها. ويمكن تعريف قطعة الأرض بأنها مساحة أرضية معينة ومخصصة لأن تستخدم في غرض محدد وفقًا للتقسيمات الرسمية، وتشمل التخصيصات السكنية والتجارية والصناعية والحكومية.

هذه الدراسة تم عملها في مدينة الرياض وهي نفس منطقة دراستنا ولكن تختلف عن دراستنا في انها ركزت على الحد الأعلى لأنظمة الطاقة الشمسية الكهروضوئية. وكما أن هذه الدراسة ركزت على استخدامات الأراضي وهذا لا يعكس الواقع بنسبة كبيرة؛ كون ان بعض الأراضي هي عبارة عن مباني وقد تختلف النسبة المخرجة في المبنى عن مساحة استخدام الأرض. كما أوصت هذه الدراسة باستخدام بيانات LiDAR.

• دراسة (Chen et al., 2018):

تطرقت الدراسة إلى انه تم إجراء العديد من الدراسات لإنشاء نماذج معلومات البناء (BIMs) أو ١٦ نموذجا لمعلومات المدينة (CIMs) كبنية تحتية رقمية لدعم مختلف برامج المدن الذكية. ولكن فإن التوليد التلقائي لمثل هذه النماذج للمناطق الحضرية عالية الكثافة لا يزال يمثل تحديًا بسبب كل من (أ) الظروف الطبوغرافية المعقدة، (ب) التعقيد الحسابي المتزايد بشكل كبير عندما تكون المهمة إعادة بناء مئات المباني على نطاق حضري. تطور هذه الورقة طرق متعددة لإعادة تصنيف البناء التلقائي في المناطق الحضرية عالية الدقة. من خلال استرداد البيانات الجغرافية لقاعدة المبنى والارتفاع والبصمة من ٢٣ خريطة طبوغرافية. تم بعد ذلك الكشف عن بدائل هندسية من نقاط LiDAR. أظهرت نتائج التقييم أن mSTEP هي طريقة فعالة لإعادة بناء BIM ويمكنها تحسين مستوى الأتمتة بشكل كبير وتقليل وقت الحساب. mSTEP قابل للتطبيق بشكل جيد على السحب النقطية ذات الكثافات المختلفة.

• دراسة (Li & Liang, 2015):

في هذه الدراسة تم توضيح العلاقة بين دالة توزيع الانعكاس ثنائي الاتجاه (BRDF) bidirectional reflectance distribution function وبيانات شدة ليدار، لتمييز الأسطح الخشنة والملساء. حيث تم اقتراح طريقة تكامل ابتكارية تم التحقق من صحتها على نظام ليدار كامل الموجة المضمن بالمختبر.

تم استنتاج نموذج BRDF مشتق جديد (يُطلق عليه اختصارا نموذج LL) وإدخاله في طريقة التكامل، والذي يتميز بأنه لا يقدر فقط على تقدير خصائص الأسطح الخشنة (الخرسانة) ولكن أيضا يتبع قاعدة انعكاس المواد الناعمة نسبيا (البلاط والبلاط المزجج). يمكن استخدام نموذج LL في تمييز مواد البناء الحضرية من حيث الخشونة والانعكاس، مما يساعد على تحديد ميزات السطح باستخدام بيانات شدة ليدار بطريقة معقولة.

سيتم الاستفادة من هذه الدراسة لفهم العلاقة بين بيانات شدة ليدار ونوعية السطح، سواء كان خشنا أو ناعما، وذلك بهدف تصنيف أنواع الأسطح في منطقة الدراسة.

• دراسة (Awrangjeb & Lu, 2013):

تم في هذه الورقة البحثية تقديم تقنية تقسيم جديدة باستخدام بيانات سحابة نقاط الليدار لاستخراج تلقائي لأسطح المباني. تم تصنيف النقاط الخام لليدار إلى نقاط أرضية ونقاط غير أرضية، وتم إنشاء قناع للمباني لتمثيل المناطق الأرضية. تم تقسيم النقاط غير الأرضية بعد ذلك لاستخراج قطاعات أفقية للأسطح. تُعالج القطاعات المستخرجة باستخدام إجراءات قائمة على القواعد، وتتم إزالة الأشجار. تقدم الطريقة المقترحة معدلات كشف عالية للمباني واستخراج الأسطح على أساس نتائج تجريبية من ثلاث مواقع في أستراليا.

الطريقة المقترحة قادرة على اكتشاف المباني بحجم أقل من ١٠ متر مربع وأسطح بمساحة تصل إلى ١ متر مربع. تعمل الطريقة بشكل حصري على بيانات الليدار، مما يوفر مرونة في التطبيقات التي لا تتوفر فيها صورة جوية. تساعد تقنية التجميع clustering في إزالة الأشجار وفصل النباتات الكثيفة إلى أجزاء صغيرة.

• دراسة (C. K. Wang & Hsu, 2007):

اقترحت هذه الدراسة طريقة لاكتشاف المباني واستخراج خطوط الكائنات من بيانات LiDAR. حيث يعالج النهج المقترح ذلك أولاً عن طريق اكتشاف موقع كل مبنى في بيانات LiDAR الخام. يعتمد اكتشاف المباني على تحويل wavelet والخصائص الهندسية للمباني. بعد ذلك يتم استخراج خطوط الكائنات، التي تنقسم إلى خطوط الـ contour الخارجية وخطوط الهيكل الداخلي، باستخدام تحويل Hough ومعالجة الصور. هذه الخطوط ضرورية لإعادة بناء المباني بناءً على البيانات. لقد أثبتت الطريقة نجاحها في استخراج خطوط الكائنات للأسقف العادية والبسيطة مثل الأسقف المستطيلة والأسقف المثلثية وأسقف النوع L.

• دراسة (Rutzinger et al., 2006):

تم في هذه الدراسة تقديم رؤية وافية حول سير عمل خوارزمية اكتشاف المباني التي تحلل بيانات المسح بالليزر من الطائرات باستخدام برمجيات مفتوحة المصدر. تم إعداد الإجراء في بيئة نظام المعلومات الجغرافية GRASS GIS. يتم استخراج المباني حصريًا من بيانات المسح بالليزر من الطائرات ومشتقاتها دون استخدام أي مصدر بيانات إضافي (على سبيل المثال، مرئيات عالية الدقة). تم اعتماد الطريقة المبنية على الكائنات لتحديد حدود المباني باستخدام تقنيات الاستشعار عن بُعد ونظم المعلومات الجغرافية. تعتمد الطريقة المبنية على الكائنات على تحديد حاد لحدود الكائنات، وهو ميزة في حالة اكتشاف المباني.

تتكون المنطقة من أنواع مختلفة من الغطاء الأرضي مثل المناطق السكنية، والغابات، والأراضي الزراعية، بالإضافة إلى عناصر البنية التحتية مثل السكك الحديدية والطرق السريعة وخطوط الكهرباء. تشمل المناطق السكنية المبنية مناطق سكنية كثيفة، ومنازل فردية مع حدائق وأشجار، ومبان صناعية كبيرة. تم إنشاء نموذج ارتفاع سطح الأرض (DSM) ونموذج الفرق بين أول وآخر نبضة بدقة ١ متر وهو من المتطلبات الرئيسية لتحقيق تجزئة ناجحة استنادًا إلى معلومات الارتفاع. تم استخدام طبقة أبنية من الخريطة العقارية الرقمية (DCM) لفورارلبرغ/النمسا محولة الى النوع المصفوفي بدقة ١ متر كبيانات مرجعية.

سيتم الاستفادة من هذه الدارسة في جزء من المنهجية العامة وطريقة تقييم الدقة. غير اننا في دراستنا سنستخدم منصة ArcGIS Pro لعملية تجزئة غمامة نقاط الليدار وتقسيم أسطح المباني وإجراءات تبسيط المباني. كم أننا سنستخدم مرئيات عالية الدقة كبيانات مرجعية لتقييم الدقة.

٥. مواد البحث النظرية:

٥.١. مفهوم الليدار:

تُستخدم أنظمة الكشف عن الضوء والمدى المحمول جواً (LiDAR) بشكل أساسي للحصول على الإحداثيات ثلاثية الأبعاد للأجسام الموجودة على سطح الأرض لإنشاء نماذج تفصيلية للارتفاعات والطبوغرافية. لقد أصبحت وسيلة فعالة للحصول على معلومات ثلاثية الأبعاد في السنوات الأخيرة (Yi et al., 2016). تعتمد معظم خوارزميات استخراج الميزات والتعرف على الكائنات باستخدام بيانات LiDAR المحمولة جواً بشكل أساسي على المعلومات الهندسية ثلاثية الأبعاد لنقاط الليزر. بالإضافة إلى تسجيل بعض المعلومات الأخرى، مثل شدة الانعكاسية intensity.

٥.٢. اكتشاف واستخلاص اسطح المباني من بيانات الليدار:

تقسم خوارزميات استخراج أسطح المباني، التي تعتمد على بيانات سحابة النقاط، إلى نوعين وفقًا لدراسة Wang وآخرين في عام ٢٠٢٤ (J. Wang et al., 2024). فيما يتعلق بالطريقة غير المباشرة للاستخراج، يتم تصنيف بيانات سحابة النقاط أولاً وتحويلها إلى صورة عمق، يلي ذلك اكتشاف حدود المبنى في صورة العمق باستخدام خوارزميات معالجة الصور. تتطلب هذه الخوارزميات تحويل بيانات سحابة النقاط ثلاثية الأبعاد إلى بيانات مصفوفية ثنائية الأبعاد (بعد المعالجة الأولية والفلترة). كما يمكن استخلاص ارتفاع المباني مباشرة من حساب نموذج السطح الرقمي المعياري (nDSM) لمجموعة بيانات DEM (Esch et al., 2022; Huang et al., 2022). من خلال خوارزميات معالجة الصور أيضا يمكن استخلاص أسطح المباني.

أما الطريقة المباشرة للاستخراج، والتي لا تحتاج إلى تحويل البيانات، يمكن تقسيمها إلى ثلاث فئات: طريقة الاستخراج القائمة على شبكة المثلثات غير المنتظمة (TIN)، وطريقة الاستخراج القائمة على ملامح بيانات سحابة النقاط، وطريقة الاستخراج القائمة على التعلم الآلي. تشمل خوارزميات استخراج البيانات القائمة على (TIN) أشكال ألفا (Alpha Shapes)، والغلاف القاسي (Convex Hull)،

والغلاف المحدب (Concave Hull). ومن بين هذه الخوارزميات، يُعتبر استخدام أشكال ألفا الأكثر شيوعًا لاستخراج حدود المبنى.

فيما يلي عرض مبسط لأسلوب لاكتشاف أسطح المباني بالطريقة غير المباشرة بناءًا على أدوات التحليل الهيدرولوجي في GIS:

تستخدم هذه الطريقة أدوات التحليل الهيدرولوجي في GIS لاكتشاف المباني (Rutzinger et al., 2009). تكون البيانات المطلوبة هي نموذج سطح رقمي (DSM) بتنسيق نقطي (Raster)، ونموذج يصف الفروق بين أول وآخر انعكاس، يتم إنشاؤهما من سحابة النقاط الخام للمسح الليزر الجوي (Hoefle et al., 2006; Rutzinger et al., 2006). تُستخدم الفروق بين أول وآخر انعكاس بشكل أساسي لاكتشاف النباتات. يتم عكس نموذج السطح الرقمي في الاتجاه الرأسي، ويُستخدم خوارزمية هيدرولوجية لملء الحفر لاكتشاف الظواهر "العالية".

يتم تحسين الأجزاء بواسطة التصفية المورفولوجية ومعيار المساحة لإزالة الضوضاء. ثم يتم حساب معاملات تعتمد على سحابة النقاط أو الطبقات المصفوفية لفصل المباني عن الظواهر الأخرى. المعاملات البارزة لتصنيف المباني تتضمن، على سبيل المثال، مؤشر الشكل، والخشونة السطحية، ومتوسط الفرق بين أول وآخر انعكاس، أو المساحة. يتم اختيار الميزة وتصميم قاعدة التصنيف بواسطة شجرة التصنيف. يمكن تحسين النتيجة عن طريق التكيف التكراري لاختيار الميزات وتحديد نطاق القيم في قاعدة القرار (Rutzinger et al., 2009).

يتم اختيار المعلمات بناءً على مناطق التدريب. يجب أخذ الحيطة في اختيار منطقة نموذجية للحصول على نتائج شاملة مثلى. يتم العثور على المعلمات الأمثل للتقسيم (الارتفاع، الانفتاح المورفولوجي، المساحة الدنيا) عن طريق البحث الشامل في جميع الحلول الممكنة. كما يجب توفير نطاق وعرض خطوة مناسب لمعلمات التقسيم. يتم اختيار ميزات الكائن (على سبيل المثال، مؤشر الشكل) المستخدمة في التصنيف من قبل المستخدم، الذي يمكنه أيضا تعريف أوزان للميزات الفردية. يتم استنتاج مقياس الجودة لكل قطعة ويُظهر مدى تناسب القطعة مع فئة البناء، ويتم استخدام القطع الجيدة فقط لمزيد من المعالجة. التصنيف نفسه (اختيار الميزة وتعريف قواعد التصنيف) يستند إلى شجرة التصنيف. التحسينات اليدوية على قاعدة قرار التصنيف تعزز نتائج التصنيف لموقع الاختبار بأكمله (Rutzinger et al., 2009).

٥.٢.١. فلترة النقاط الأرضية:

فصل السحابات النقطية إلى قياسات أرضية وغير أرضية هي خطوة أساسية لإنشاء نماذج التضاريس الرقمية (DTMs) من بيانات LiDAR الجوية (Zhang et al., 2016). ومع ذلك، تحتاج معظم خوارزميات التصفية إلى إعداد عدد من المعلمات المعقدة بعناية لتحقيق دقة عالية.

- **فلتر المحاكاة القماشية (CSF):**

يعتبر فلتر المحاكاة القماشية Cloth Simulation Filter (CSF) التي تم تطويره من قبل (Zhang et al., 2016) طريقة شائعة الاستخدام لتصفية نقاط السحابة لـ LiDAR و UAS. هذه الطريقة مشهورة بسبب بساطة إعداداتها والعدد الكبير من نقاط الأرض التي تنتجها، مما يجعلها طريقة تصفية موثوقة . إن خوارزمية CSF مفيدة بشكل خاص في التطبيقات مثل المسح الليزري الجوي، ونمذجة التضاريس، واستخراج علامات سطح الطريق.

تحتاج CSF فقط إلى بعض المعلمات البسيطة السهلة الإعداد. ضمن النهج المقترح، يتم عكس سحابة نقاط LiDAR، ثم يتم استخدام قماش صلب لتغطية السطح المعكوس. من خلال تحليل التفاعلات بين عقد القماش ونقاط LiDAR المقابلة، يمكن تحديد مواقع عقد القماش لإنشاء تقريب لسطح الأرض. وأخيرًا، يمكن استخراج نقاط الأرض من سحابة نقاط LiDAR عن طريق مقارنة نقاط LiDAR الأصلية والسطح المنشأ.

واحدة من المزايا الرئيسية لطريقة CSF هي قابليتها للتكيف. يمكن استخدامها مع أنواع مختلفة من البيانات وفي تطبيقات متنوعة. على سبيل المثال، تم استخدامها لفصل نقاط الأرض عن النقاط غير الأرضية في المناطق الغابية، وهي مهمة صعبة بسبب تعقيد التضاريس ووجود النباتات.

- **الفلاتر المتوفرة في برامج GIS:**

خوارزميات تصنيف نقاط سحابة الليدار المتوفرة في برنامج ArcGIS Pro تأتي بثلاثة خيارات. الطريقة الأولى تسمى "الطريقة القياسية"، الطريقة الثانية، التي تسمى "المحافظة" والطريقة الثالثة تعرف بـ "العدوانية (عنيفة أو متشددة)" (Esri, 2024). على عكس CSF تأتي خوارزميات تصنيف الأرض في ArcGIS مع معلمات اختيارية افتراضية مثل إعادة استخدام نقاط الأرض الموجودة أثناء تصنيف الأرض، مما يوفر مزيدا من الأتمتة ولكن مع قليل من التحكم في عملية التصنيف. وبالتالي، فإن

معالجة سحابة النقاط باستخدام ArcGIS هي عبارة عن حل شامل بصندوق أسود مع صيغة رياضية أساسية غير معروفة (Klápště et al., 2020).

تصنيف قياسي Standard: يتميز هذا الأسلوب بدرجة من التسامح تجاه اختلافات الانحدار مما يسمح بتحديد التغيرات التدريجية في تضاريس الأرض التي قد تفوتها طريقة التصنيف المحافظ، ولكن لا يكشف عن التضاريس الحادة التي يمكن اكتشافها بواسطة طريقة التصنيف العنيف.

تصنيف محافظ Conservative: يستخدم هذا الأسلوب قيودا أكثر صرامة على اختلاف انحدار الأرض مما يسمح بتمييز الأرض عن الغطاء النباتي المنخفض مثل العشب والأشجار الصغيرة. إنه مناسب بشكل أفضل للتضاريس ذات الحد الأدنى من الانحناء.

تصنيف عنيف أو متشدد Aggressive: يكتشف هذا الأسلوب مناطق الأرض ذات التضاريس الحادة، مثل التلال وقمم التلال، والتي قد يتم تجاهلها بواسطة طريقة التصنيف القياسي. هذا الأسلوب هو الأفضل استخدامًا في دورة ثانية من هذه الأداة مع تحديد خيار "إعادة استخدام الأرض الموجودة". ويجب تجنب استخدام هذا الأسلوب في المناطق الحضرية أو المناطق الريفية المسطحة، حيث قد يؤدي ذلك إلى تصنيف الأشياء الأطول – مثل أبراج المرافق، والنباتات، وبعض أجزاء المباني – على أنها أرض.

خلال هذه العملية، يُمكن أيضًا تحديد قيمة دقة نموذج الارتفاع الرقمي (DEM Resolution) لتحقيق نتائج أسرع، وذلك إذا كانت النقاط المُصنفة كنقاط الأرض ستُستخدم في إنشاء سطح تضاريس رقمي للأرض بدقة محددة. يتم تحسين الأداء عبر تقليل عدد النقاط المخصصة لرمز الأرض، مع الحفاظ على التغطية الضرورية للدقة المطلوبة.

عند تصنيف إرجاعات LAS على تضاريس ذي خصائص ميل متفاوتة، مثل المناطق المستوية نسبيا جنبًا إلى جنب مع المواقع ذات الميل الحاد، يُنصح بتشغيل مصنف الأرض مرة واحدة باستخدام الطريقة القياسية، وثانية باستخدام طريقة الكشف العنيف مع تفعيل خيار "إعادة استخدام الأرض".

٥.٢.٢. تحويل بيانات ليدار الى نقطية (Raster):

يتم استخدام التابع LAS To Raster لتحويل بيانات LiDAR المخزنة باستخدام تنسيق ملف LAS إلى بيانات من نوع نقطي ESRI (Raster) (٢٠٢٤). تقدم نقاط الأرض LAS العديد من المعلومات حول ارتفاع الأرض، ولكن هناك مسافة بين النقاط حيث يكون الارتفاع غير معروف.

تستخدم أداة LAS Dataset To Raster نموذجًا رياضيًا لحساب (أو تنبؤ) الارتفاع في هذه المناطق غير المعروفة استنادًا إلى قيم نقاط الأرض الحالية. يُطلق على هذه العملية اسم الاستيفاء. وهنا يجب علينا تحديد خصائص الإدخال والإخراج. من بين هذه الخصاص: حقل القيمة المستخدمة، تحديد حجم الخلية الناتجة، نوع الاستيفاء.

٥.٢.٣. ضوضاء سحابة الليدار (النقاط الشاذة noise points):

عند التقاط سحب نقاط ثلاثية الأبعاد بمقياس كبير باستخدام أجهزة استشعار LiDAR، يؤدي إطلاق النبضات الليزرية من الماسح الضوئي إلى تكوين آثار انعكاس غير مرغوب فيها ونقاط افتراضية (ضوضاء) في الفضاء ثلاثي الأبعاد (Gao et al., 2021). نقاط ضوضاء سحابة LiDAR هي نقاط تُصنف على أنها نقاط شاذة في سحابة نقاط LiDAR. يمكن أن تحدث نقاط الضوضاء بسبب عوامل مختلفة، مثل: أخطاء الاستشعار، الظروف الجوية، الانعكاسات،..الخ. يمكن لنقاط الضوضاء أن تؤثر على جودة ودقة بيانات LiDAR، وبالتالي يجب اكتشافها وإزالتها. تعتمد إحدى طرق إزالة الضوضاء على تباين السطح المحلي (LVS) لسحابة النقاط، والذي يقيس انحراف السطح المحلي عن السطح الكلي. يمكن لطريقة LVS تحديد نقاط ضوضاء LiDAR عن طريق مقارنة قيم LVS لكل نقطة مع حد محدد مسبقا (Zhu et al., 2023).

٥.٢.٤. قيم شدة بيانات LiDAR (intensity):

يحظى تحليل بيانات قيم شدة (LiDAR) لاستخراج ميزات السطح باهتمام كبير في أبحاث الاستشعار عن بعد. أحد التطبيقات الممكنة لبيانات قيم شدة LiDAR هو تصنيف الأهداف (Li & Liang, 2015). يمكن أن تتضمن بيانات LiDAR قيم شدة تمثل قوة إشارة الليزر المرتدة ويمكن أن توفر معلومات إضافية حول خصائص سطح الهدف (Kuras et al., 2021).

تتميز الخرسانة بأنها عالية الانعكاسية لضوء الليزر، مما ينتج عنه ارتفاع قيم الشدة في بيانات LiDAR. هذه القيم المرتفعة للشدّة تساعد على تمييز أسطح المباني المصنوعة من الخرسانة في بيانات LiDAR عن الأسطح المصنوعة من مواد أخرى ذات انعكاسية أقل (Yi et al., 2016).

صحيح أن قيم شدة LiDAR للخرسانة مرتفعة بشكل عام، إلا أن قيم شدة بيانات LiDAR تتأثر بعوامل عديدة إلى جانب خصائص سطح الخرسانة نفسها، مما يحد من دقتها وموثوقيتها. حيث يمكن أن

تتباين اعتمادا على عدة عوامل: (Kaartinen et al., 2022; Kashani et al., 2015; Kuras et al., 2021; Park & Cho, 2021; Song et al., 2002; Yi et al., 2016).

- نوع الخرسانة: التركيبة الدقيقة للخرسانة (مثل محتوى الإسمنت والركام) يمكن أن تؤثر على انعكاسية الليزر.
- خشونة السطح: الأسطح الخشنة للخرسانة تميل إلى عكس الضوء بشكل غير منتظم، مما قد يؤدي إلى قيم شدة أقل مقارنة بالأسطح الأملس.
- الرطوبة: امتصاص الماء يمكن أن يقلل من انعكاسية الليزر للخرسانة، مما يؤدي إلى انخفاض قيم الشدة.
- الملمس: الأسطح المصقولة أو المطلية لها خصائص انعكاسية مختلفة عن الخرسانة العادية، مما ينتج عنه اختلاف في قيم الشدة.

بالإضافة لعوامل أخرى مثل الظروف الجوية وإعدادات الجهاز.

يؤثر نسيج السطح وخشونته ولونه بشكل كبير على شدة انعكاسه للضوء. على سبيل المثال، يعكس السطح الخرساني الأملس شدة أكثر مقارنة بالسطح الخشن أو المتآكل. وبالتالي، لا توجد قيم ثابتة لشدة انعكاس اشرارة الليدار لكل نوع من أنواع الأسطح. لذلك، قمنا في بحثنا بتحديد نوع السقف من خلال المعاينة الميدانية (الفحص البصري)، وتجميع بيانات مرجعية وتحليل قيم شدة الانعكاس لكل مادة ضمن مجموعة البيانات. وقد وفر لنا ذلك نطاقا أكثر دقة لشدّة الانعكاس في منطقة الدراسة.

على الرغم من أن قيم شدة LiDAR يمكن أن توفر معلومات قيمة حول أسطح الخرسانة، إلا أن العلاقة بينهما معقدة وليست مباشرة دائما (Kaartinen et al., 2022). لذلك ، من المهم استخدام قيم شدة LiDAR إلى جانب تقنيات أخرى.

٥.٢.٥. التصنيف الهدفي:

أصبح التصنيف الهدفي (OBIA) الطريقة الأساسية المتقدمة لتحليل ومعالجة الصور. في حوالي عام ٢٠٠٠، بدأ (GIS) ومعالجة الصور بالنمو المتسارع معا من خلال OBIA لتحليل المرئيات القائم على الكائنات. وبناءً على ذلك، تم تحقيق تقدم ملحوظ في الاستشعار عن بعد في العقود الأخيرة. هنالك عدة عوامل ساهمت في الوقت نفسه في هذه النجاحات البارزة، خاصة في مجال معالجة صور الأقمار الصناعية، منها إجراءات إنشاء المعرفة مثل مجال OBIA. تتجه أهم ميزة في OBIA إلى التصنيف

الموجه للكائنات، والذي يستخدم كل من المعلومات الطيفية والمكانية للتصنيف. تتضمن العملية تصنيف البكسلات بناءً على خصائصها الطيفية والشكل والملمس والعلاقة المكانية مع البكسلات المحيطة. (Rasouli et al 2021).

في التطبيق العملي، يعتبر OBIA أحد الأساليب المتعددة التي تم تطويرها للتغلب على قيود الطرق القائمة على البكسلات. فهو يدمج معلومات طيفية ونسيجية وسياقية لتحديد الفئات الغرضية في الصورة. وبالتالي، فإن OBIA مناسب لتصنيف صور الأقمار الصناعية عالية الدقة.

الخطوة الأولى في OBIA هي تقسيم أو تجزئة Segmentation الصورة إلى كائنات متجانسة. تستند عملية التقسيم على معايير محددة مسبقا مثل الاكتناز أو التركز compactness، والشكل، والحجم، والتي تستمد من المعرفة الواقعية بميزات العناصر التي نرغب في تحديدها.

في الخطوة الثانية، يمثل كل كائن (قطعة) الخصائص الإحصائية للبكسلات الموجودة فيه. وهذا يعني أنه يتم تخصيص جميع البكسلات داخل قطعة إلى فئة واحدة، مما يلغي تباين الطيف داخل المجال ومشاكل البكسلات المختلطة المرتبطة بالطرق القائمة على البكسلات. التصنيف المراقب وغير المراقب يعتمد على البكسلات. وبعبارة أخرى، فإنه ينشئ بكسلات مربعة، ويكون لكل بكسل فئة. أما OBIA فتجمع البكسلات في أشكال متجهة vector تمثيلية بحجم وهندسة محددين.

في التصنيف القائم على OBIA، يمكن استخدام طرق مختلفة لتصنيف الكائنات، على سبيل المثال (Rasouli et al 2021):

- الشكل SHAPE: إذا كنا نريد تصنيف المباني، يمكن استخدام إحصائية الشكل مثل "الملائمة المستطيلة" التي تختبر هندسة الكائن بالنسبة إلى شكل المستطيل.
- الملمس TEXTURE: الملمس هو تجانس الكائن. على سبيل المثال، يكون الماء متجانسا في الغالب لأنه أزرق داكن. لكن الغابات تحتوي على ظلال ومزيج من الأخضر والأسود.
- الطيف SPECTRAL: يمكن الاستفادة من القيمة المتوسطة للخصائص الطيفية مثل الأشعة تحت الحمراء القريبة، والأشعة تحت الحمراء قصيرة الموجة، والأحمر، والأخضر، أو النطاق الأزرق.
- السياق الجغرافي GEOGRAPHIC CONTEXT: ترتبط الكائنات بعلاقات القرب والمسافة بين الجيران.

وبالتالي، يستخدم تصنيف OBIA شكل الكائنات وحجمها وخصائصها الطيفية لتصنيف كل كائن. في المقابل، عند استخدام تقنيات التصنيف التقليدية للصور، غالبا ما نحصل على نتيجة تصنيف ذات مظهر "ملح وفلفل salt and pepper".

٥.٣. تقييم الدقة:

٥.٣.١. تقييم دقة تجزئة غمامة الليدار:

اقترح (Kushwaha et al., 2019) طريقة تقييم دقة تجزئة بيانات الليدار، حيث اختار الباحثون ثلاث بنايات بشكل عشوائي من أجل تقييم دقة التجزئة، واستخدموا معادلة رقم (١) لتقييم دقة نتائجها. والتي يمكن استخدامها في دراستنا لتقييم نتائج تجزئة بيانات الليدار في منطقة الدراسة. حيث تحسب نسبة الدقة كنسبة مئوية بقسمة عدد النقاط المجزئة بالطريقة المتبعة على عدد النقاط المجزئة يدويا.

$$\text{Percentage accuracy} = \frac{\text{No.of points segmented by the suived method}}{\text{No.of points segmented manually}} * 100 \quad (1)$$

٥.٣.٢. تقييم دقة تصنيف أنواع الأسطح:

في الوقت الحالي يعد التحقق من الصحة أو تقييم الدقة جزءا لا يتجزأ من معظم مشاريع رسم الخرائط التي تتضمن بيانات الاستشعار عن بعد. في الثمانينيات، أصبح استخدام مصفوفة الأخطاء Classification Error Matrix أو مصفوفة الارتباك (confusion matrix) أداة شائعة لتمثيل دقة فئات الخرائط الفردية. بحلول التسعينيات، كانت معظم الخرائط المستمدة من مرئيات الاستشعار عن بعد مطلوبة لتلبية بعض معايير الحد الأدنى من الدقة (Congalton, 2001).

تحتوي الصورة المصنفة على الكثير من الأخطاء. يعطي تقييم دقة الصورة المصنفة جودة المعلومات التي يمكن الحصول عليها من بيانات الاستشعار عن بعد. لتقييم دقة التصنيف المعتمد على البكسل عادةً ما يتم استخدام مصفوفة الارتباك (confusion matrix) والمقاييس المشتقة مثل معامل كابا kappa coefficient والدقة الكلية Overall accuracy (Foody, 2009; Olofsson et al., 2014)، ومقاييس أخرى مثل دقة المنتج Producer's accuracy ودقة المستخدم User's accuracy.

تعد مصفوفة الارتباك أحد أكثر الوسائل شيوعا للتعبير عن دقة التصنيف. تتمثل المهمة الأولى في تحديد وحدات بكسل الاختبار المرجعية الأرضية أو مجموعة العينات، بناءً على تكوين مصفوفة الخطأ. وتتضمن العديد من الأساليب الرياضية. يمكن أخذ عينات البيانات باستخدام إجراءات مختلفة

مثل: عشوائية، منهجية، عشوائية طبقية، منهجية طبقية غير متوازنة، وعنقودية. تقارن مصفوفة الخطأ العلاقة بين البيانات المرجعية المعروفة (البيانات الأرضية) والنتائج المقابلة التي تم الحصول عليها من التصنيف. سنعتمد هذه المعايير لتقييم دقة تصنيف أنواع الأسطح في بحثنا.

٥.٣.٣. تقييم دقة التصنيف الهدفي:

أما بالنسبة لتقييم الدقة في تقنيات التصنيف الهدفي، فإن مقاييس الدقة المقبولة من قبل المجتمع البحثي هي الاكتمال (Comp) والصحة (Corr)، حيث يتم استخدام مقاييس مشتقة من مزيج هذين الاثنين، وتُعرف بـ "الجودة" Quality لتحديد الدقة الإجمالية (Adeleke & Smit, 2020; Rutzinger et al., 2009).

عادةً ما يكون الهدف من اكتشاف الكائنات هو التمييز بين فئتين، الكائن والخلفية. من خلال مقارنة نتائج الاستخراج الآلي بالبيانات المرجعية، يُشير الإيجابي الحقيقي (TP) إلى كائن مصنف يتطابق تماما مع تسمية الكائن المقابلة له في البيانات المرجعية. بينما الإيجابي الكاذب (FP) هو كيان مصنف على أنه كائن، لكنه لا يتوافق مع كائن في البيانات المرجعية. والكائن الذي يُوجد في البيانات المرجعية والذي تم تصنيفه كخلفية أو حذفه بشكل خاطئ في نتيجة التصنيف يُسمى سلبيا كاذبا (FN)، وهو الجزء الذي لم يتم اكتشافه أو استخراجه في عملية الاستخراج. أما السلبي الحقيقي (TN) فيشير إلى الكائن الذي ينتمي إلى الخلفية سواء في التصنيف أو في البيانات المرجعية (Adeleke,2018;Rutzinger et al., 2009).

باستخدام هذه المعلمات، يمكن استخلاص مقاييس تقييم الدقة للاكتمال والصحة والجودة.

$$\text{Completeness} = \frac{||TP||}{||TP|| + ||FN||} \quad (1)$$

$$\text{Correctness} = \frac{||TP||}{||TP|| + ||FP||} \quad (2)$$

يمكن أيضًا الإشارة إلى الاكتمال باسم معدل الكشف أو دقة المنتج Producer's Accuracy وهي نسبة الكائنات في البيانات المرجعية التي تم اكتشافها. يُشار أيضا إلى الصحة بمصطلح دقة المستخدم User's Accuracy وهي تشير إلى مدى تطابق الكائنات المكتشفة مع البيانات المرجعية وترتبط بشكل وثيق بمعدل الإنذار الكاذب. يجب أن يتمتع التصنيف الجيد بكل من ارتفاع الاكتمال والصحة. تقدم

جودة النتائج مقياس أداء مركب يتوازن بين الاكتمال والصحة ويُشار له بمصطلح الدقة الإجمالية (Adeleke, 2018; Foody, 2002; Rutzinger et al., 2009).

$$Quality = \frac{\|TP\|}{\|TP\| + \|FP\| + \|FN\|} \quad (3)$$

$$Quality = \frac{Comp \cdot Corr}{Comp + Corr - Comp \cdot Corr}. \quad (4)$$

٦. منطقة الدراسة:

تقع منطقة الدراسة شمال لمدينة الرياض في المملكة العربية السعودية الشكل ١.تمتد المنطقة بين دائرتي عرض ٢٤,٦٩٦١٢٣°-٢٤,٧٣٥٥١٢° شمالا وخطي طول ٤٦,٦٠٢١١٠°-٤٦,٦٥٤٠٩٨° شرقا ضمن نظام الاحداثيات العالمي WGS 1984. ترتفع المنطقة عن سطح البحر بمتوسط يقدر بحوالي ٦٣٠ مترًا. تتراوح تضاريس الأرض في المنطقة بين ٦٠٨ مترًا في الجنوب الغربي و٦٥٥ مترًا في الشمال. وتعتبر المنطقة منطقة حضرية كثيفة تضم خصائص متنوعة من الأسطح في الهياكل الحضرية.

تشمل منطقة الدراسة عدة أحياء ومواقع مهمة. تتضمن الحدود المكانية للدراسة حي جامعة الملك سعود، وحي الرائد، بالإضافة إلى مدينة الملك عبد العزيز للعلوم والتقنية. تتميز منطقة الدراسة بتنوع الأسطح الموجودة فيها، حيث تتميز أسطح جامعة الملك سعود بخشونتها، بينما تتنوع أسطح المباني السكنية وتتألف من خرسانة أو بلاط.

تم اختيار هذه المنطقة للدراسة بسبب وجود العديد من العناصر الحضرية فيها، مثل المباني ذات الأسطح المختلفة، والطرق، وبعض الأشجار. بالإضافة إلى ذلك، تم اختيار المدينة كمنطقة دراسة لأنها توفر المدخلات الأولية اللازمة، والتي تشمل مرئيات فضائية عالية الدقة جداً وبيانات LiDAR التي تغطي المنطقة بأكملها.

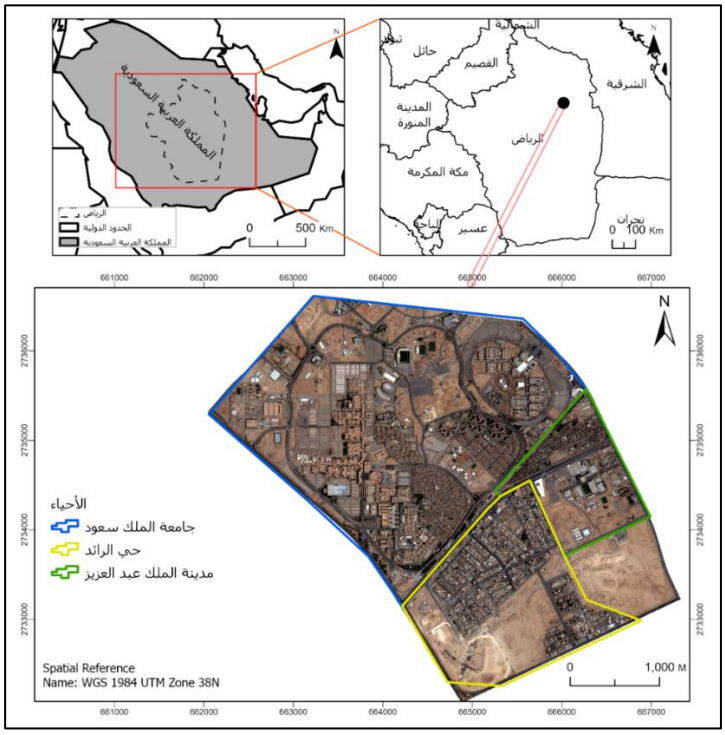

الشكل (١) منطقة الدراسة

٧. المنهجية العامة للبحث:

سنستخدم في هذا البحث بيانات سحابة الليدار لاكتشاف واستخلاص أسطح المباني وأنواعها في منطقة الدراسة. سيتم اختبار طريقتين مختلفتين لمعالجة بيانات الليدار لتحقيق أهداف البحث. تعتمد الطريقة الأولى على معالجة بيانات الليدار لاستخلاص أسطح المباني وأنواعها في بيئة GIS. أما الطريقة الثانية فتعتمد على مبدأ التصنيف الهدفي. يوضح الشكل ٢ المنهجية العامة المتبعة في هذا البحث.

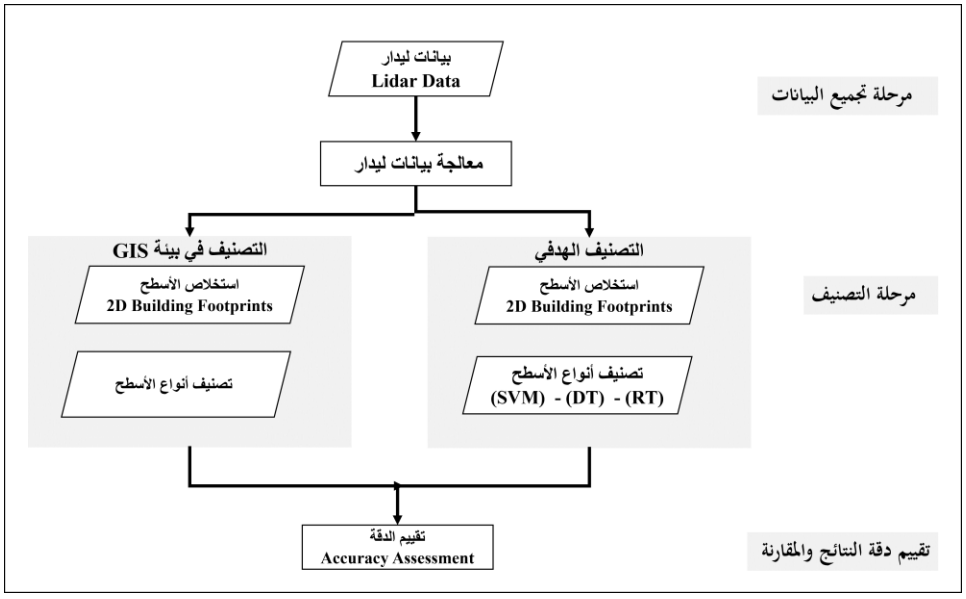

الشكل (٢) المنهجية العامة للبحث

٧.١. جمع البيانات:

تم الحصول على مجموعة بيانات ليدار من الهيئة الملكية لمدينة الرياض. تم التقاط بيانات الليدار بواسطة جهاز ليدار محمول في طائرة جوية. تعود بيانات الليدار إلى عام ٢٠١٢. يوضح الشكل غمامة نقاط الليدار لمنطقة الدراسة في برنامج ArcGIS Pro. تم جدولة معلمات مجموعة بيانات الليدار المتوفرة لمنطقة الدراسة وتظهر في الجدول (١).

الجدول (١) ملفات بيانات الليدار المتوفرة لمنطقة الدراسة مع بعض الإحصائيات

No.	LAS File	Point Count	Point Spacing	Z Min	Z Max
1	G07-e06.las	2703523	0.515	616.6	664.74
2	G07-e07.las	2622667	0.535	615.08	751.7
3	G07-e08.las	2759559	0.521	604.02	781.83
4	G07-f05.las	2840533	0.514	614.49	755.79
5	G07-f06.las	2674685	0.518	615.88	875.73
6	G07-f07.las	2754350	0.522	622.46	660.9
7	G07-f09.las	2778864	0.52	591.14	719.93
8	G07-g05.las	2953599	0.504	626,78	755.77
9	G07-g06.las	2965766	0.503	626.81	721,11
10	G07-g07.las	2848067	0.513	621.19	721.51
11	G07-g08.las	2402114	0.559	605.28	658.22
12	G07-g09.las	2790041	0.519	591.44	897.26
13	G07-h04.las	2956695	0.504	634.59	688.56
14	G07-h05.las	3002665	0.5	635.36	698.92
15	G07-h06.las	2682371	0.519	624.81	823.65
16	G07-h07.las	2726680	0.525	613.19	673.43
17	G07-h08.las	2661927	0.531	609.11	657.46
18	G07-i04.las	2770764	0.52	638.45	712.2
19	G07-i05.las	2708718	0.526	639.88	676.21
20	G07-i06.las	2620847	0.535	624.65	710.46
21	G07-i07.las	2863746	0.512	612.68	704.99
22	G07-i08.las	2727542	0.525	608.1	644.53
23	G07-j04.las	3100522	0.492	643.88	689.46
24	G07-j05.las	2731193	0.524	640.29	710.53
25	G07-j06.las	2733091	0.524	624.42	714.32
26	G07-j07.las	2744489	0.523	532.17	717.26
27	H07-a05.las	2909402	0.508	640.21	713.8
28	H07-a06.las	2660811	0.531	621.1	696.59
		Sum	**Avg.**	**Avg.**	**Avg.**
		77695231	0.519357	617.3067	721.3241

من الجدول (١) نلاحظ أن عدد الرقع هو ٢٨ وأن التباعد الوسطي بين نقاط الغيمة يقترب من ٠,٥٢ متر. كما يتبين أن عدد نقاط الغيمة بأكملها يبلغ حوالي ٧٧ مليون و٧٠٠ ألف نقطة. يتضح أيضا أن متوسط أدنى ارتفاع هو ٦١٧,٣ متر، في حين أن متوسط أعلى ارتفاع يبلغ ٧٢١,٣٢ متر. تتمتع بيانات LiDAR المتوفرة بكثافة نقاط (PD) متوسطة تبلغ أربع نقاط لكل متر مربع (= PD 4=2)1/(0.5)^2 = 1/(PS)^2).

٧.٢. معالجة بيانات الليدار لاستخلاص أسطح المباني وأنواعها في بيئة GIS:

٧.٢.١. إنشاء مجموعة بيانات الليدار LAS dataset:

لكي نتمكن من معالجة بيانات الليدار لكامل منطقة الدراسة، يجب أولاً إنشاء مجموعة بيانات الليدار (LAS Dataset). تم إنشاء هذه المجموعة وتسميتها باسم Study_Area.lasd. بعد ذلك، تم إضافة جميع ملفات الليدار المذكورة سابقا في الجدول (١) إلى مجموعة البيانات هذه. يوضح الشكل (٣) مجموعة بيانات الليدار والملفات المتضمنة فيها، بالإضافة إلى الإحصائيات لكل ملف. بلغ عدد نقاط الغمامة في مجموعة بيانات حوالي ٧٧ مليون و٧٠٠ ألف نقطة بحجم حوالي ٢ جيجا و٧٥ ميغابايت.

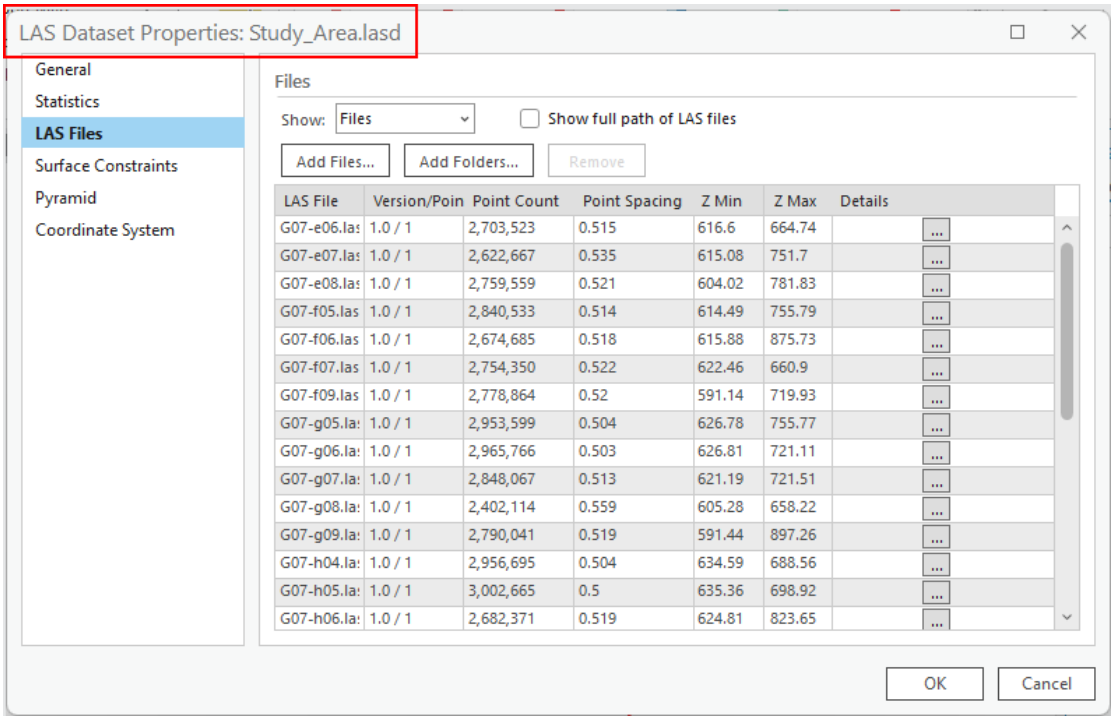

الشكل (٣) مجموعة بيانات الليدار والملفات ضمنها

كما يُوضح الشكل (٤) توزع رقع بيانات الليدار والتغطية المكانية في منطقة الدراسة، يجدر بالذكر أن هناك رقعة غير متاحة، ومع ذلك، لن تؤثر هذه الرقعة على عمليات المعالجة وإخراج النتائج. يعود ذلك إلى أن غالبية المنطقة تكون أرضا خالية من البنية التحتية.

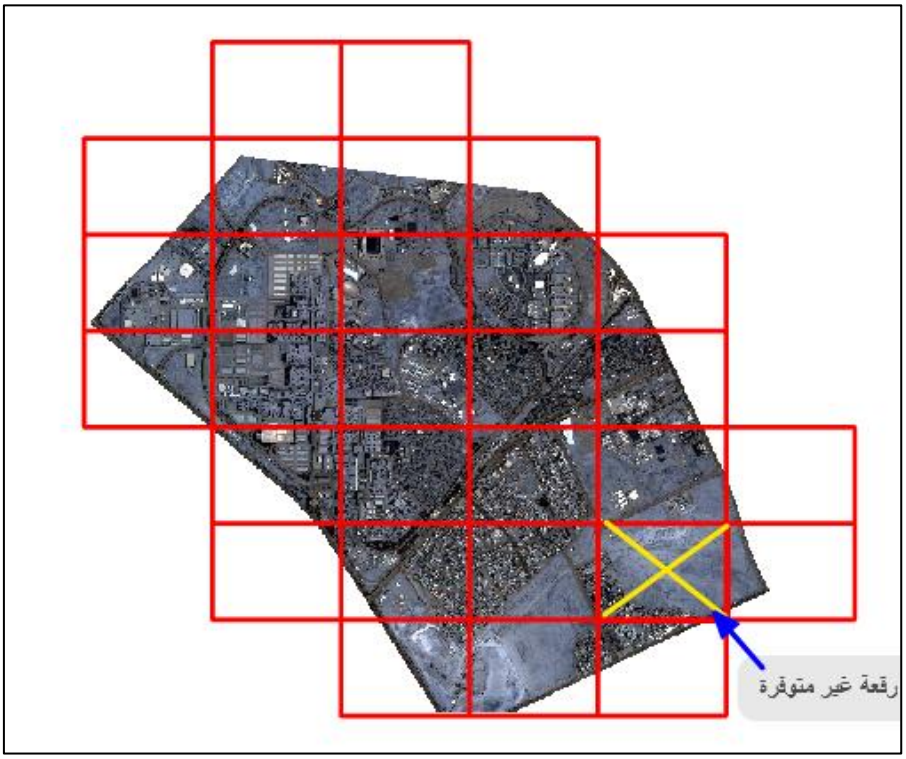

الشكل (٤) التغطية المكانية لبيانات الليدار لمنطقة الدراسة

يوضح الشكل (٥) جزءا من غيمة نقاط الليدار في برنامج ArcGIS Pro، حيث تظهر الارتفاعات بالألوان. يتم تمثيل الارتفاعات بألوان متنوعة، حيث يتراوح اللون من الأزرق الداكن (للارتفاعات المنخفضة) إلى الأحمر الداكن (للارتفاعات العالية).

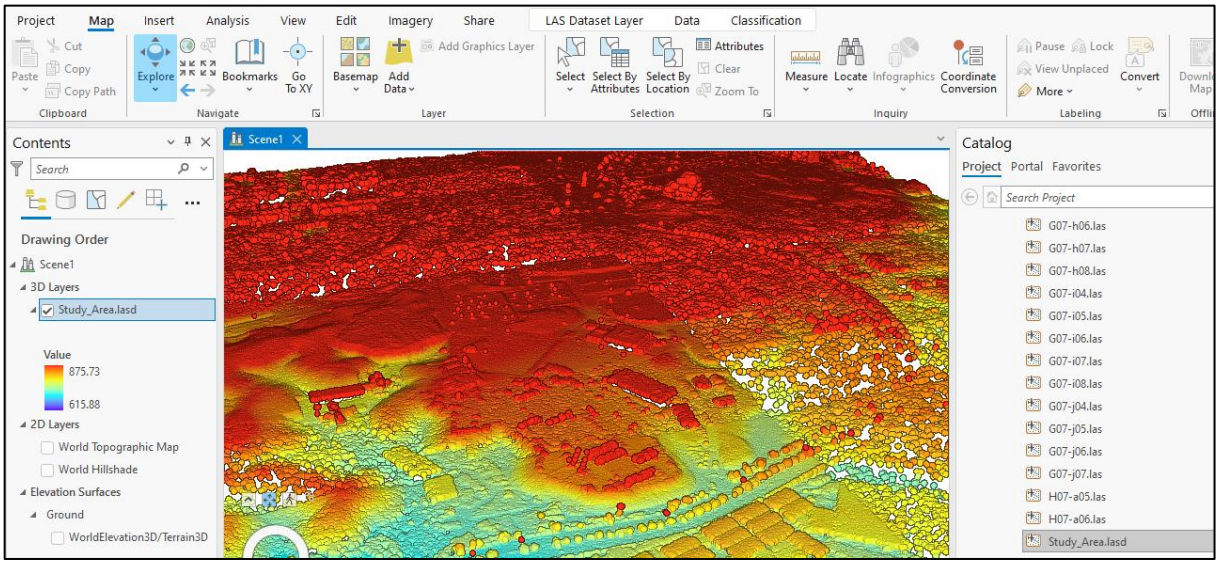

الشكل (٥) جزء من غمامة نقاط الليدار في منطقة الدراسة

بعد إنشاء مجموعة بيانات الليدار، تم اقتطاع هذه المجموعة داخل حدود منطقة الدراسة فقط، بهدف تقليل حجم البيانات وتسريع عملية المعالجة. نتج عن ذلك الحصول على مجموعة بيانات جديدة

خاصة بالمنطقة المدروسة، حيث بلغ عدد نقاط السحاب حوالي ٤٦ مليون و٦٤٠ ألف نقطة، بحجم تقريبي يبلغ ١ جيغابايت و٢٤٥ ميغابايت. يُلاحظ أن هناك انخفاضًا بنسبة ٤٠٪ في عدد النقاط وحجم البيانات.

٧.٢.٢. إزالة الضجيج (النقاط المتراكبة):

عند جمع بيانات الليدار، غالبًا ما تطير الطائرات على مسارات متداخلة لضمان تغطية كاملة للمنطقة المستهدفة. يمكن أن يؤدي هذا أحيانًا إلى نقاط مكررة في بعض المناطق من ملفات LAS. يمكن أن تؤدي هذه النقاط المكررة إلى ظهور ضوضاء في البيانات، مما قد يؤثر على دقة التحليلات أو العروض التوضيحية.

لمعالجة التداخل في ملفات LAS، يمكن استخدام أداة Classify LAS Overlap لتحديد وتمييز النقاط المتداخلة. يمكن بعد ذلك إيقاف تشغيل النقاط المتداخلة لاستبعادها من المعالجة أو العرض الإضافي.

٧.٢.٣. استخراج DSM:

قبل عملية التصنيف، تم استخدام المعالجة الجغرافية لتحويل مجموعة البيانات إلى بيانات نقطي (Raster)، الشكل (٦)، وبذلك نحصل على طبقة DSM. الإعدادات التي تم استخدامها أثناء المعالجة هي:

- حجم الخلية الناتجة ٠,٣ متر.
- استخدام تقنية Binning كنوع للاستيفاء.
- حقل الارتفاع كقيم لخلايا النقطي (Raster) الناتجة.
- طريقة الجار الأقرب كطريقة لملء الفراغات.
- استخدام نوع البيانات floating point للناتج.
- معامل Z بقيمة ١ لأن الوحدات في الاتجاه الأفقي والرأسي معرفة بالمتر.

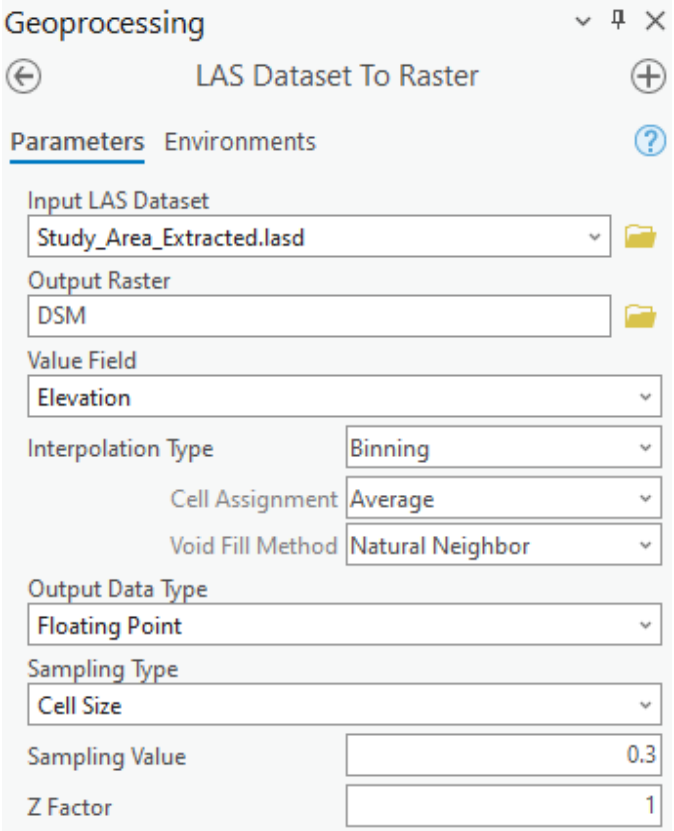

الشكل (٦) معلمات تحويل مجموعة بيانات الليدار الى سطح DSM

٧.٢.٤. انتاج خريطة الانحدار Slope والاتجاه Aspect:

بناءً على نموذج الارتفاع الرقمي (DSM)، تم استخراج طبقة الانحدار بوحدة الدرجات، وطبقة الاتجاه (Aspect). الانحدار يشير إلى معدل التغير في الارتفاع، بينما الاتجاه يشير إلى الاتجاه الذي يواجهه الانحدار. ستفيد هذه الطبقات فيما بعد أثناء عملية التصنيف الهدفي.

٧.٢.٥. تصنيف نقاط غمامة الليدار:

بعد ذلك ستتم عملية تصنيف مجموعة بيانات LAS إلى عدة فئات، مثل الأرض والمباني، باستخدام الأدوات التي تحلل موضع نقاط السحابة وخصائصها لتحديد الفئة التي تنتمي إليها. تأتي بعض السحب النقطية LAS مصنفة من مزودها الأصلي.

في حالة عدم تصنيف النقاط، أي أن جميع النقاط غير معينة لأي فئة، فإنه يتم تمثيلها بشكل متساوٍ بلون رمادي محايد. هذا التمثيل يساعد في التعرف السريع على حالة التصنيف لكل نقطة. في هذه الحالة، يقدم برنامج ArcGIS Pro فهرسا للفئات المحتملة المتاحة للتعيين. ومع ذلك، تظل غالبية

هذه الفئات غير نشطة، ولا تُستخدم داخل مجموعة بيانات LAS، ما لم يتم تصنيفها ودخولها ضمن الفئة المناسبة لها.

يوفر ArcGIS Pro مجموعة من الفئات التي يمكن أن تصنف ضمنها نقاط السحابة، والتي تبلغ حالياً ٢٥ فئة كما هو موضح بالشكل (٧).

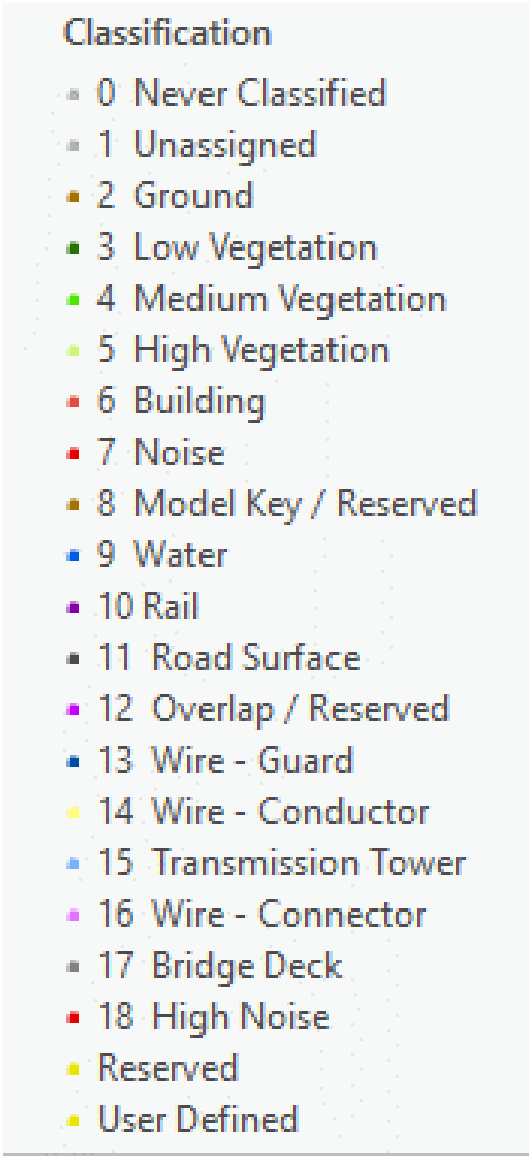

الشكل (٧) فئات تصنيف نقاط السحابة في ArcGIS Pro

- **تصنيف نقاط الأرض Classify LAS Ground:**

في هذه الخطوة، سيتم تحديد جميع نقاط السحابة التي تنتمي إلى الأرض الطبيعية. يتم ذلك باستخدام أداة تصنيف LAS Ground، والتي تبحث عن مجموعات من النقاط التي تظل ثابتة كأقل ارتفاع في المشهد بشكل مستمر.

يمكن تعيين نقاط LAS فقط التي تحمل قيم رموز الصنف ٠، ١، أو ٢ كنقاط أرض. إذا كانت ملفات LAS الخاصة بنا تستخدم قيم رموز صنف مختلفة لتمثيل القياسات غير المصنفة أو الأرض، يُفضل استخدام أداة تغيير رموز الصنف في LAS لإعادة تعيينها وفقًا للقيم المناسبة. يتجاهل عملية التصنيف أيضًا النقاط التي تم تعيينها بعلامات التصنيف "overlap" أو "withheld" ("مخفية" أو "غير متاحة").

- **انشاء DTM:**

بعد تحديد نقاط الأرض في ملف LAS، يمكن استخدامها لإنشاء نموذج ارتفاع رقمي للتضاريس (DTM= DEM)، والذي سيكون ذو فائدة لاحقة في سير العمل. يقوم هذا النموذج بتمثيل ارتفاع سطح الأرض الطبيعية كنقطي (Raster) مستمر، حيث يتم استخدام أداة LAS Dataset To Raster. تم استخدام نفس إعدادات استخراج طبقة DSM.

- **تصنيف نقاط الضوضاء:**

بعد تحديد نقاط الأرض في بيانات LAS، الخطوة التالية هي تحديد نقاط الضوضاء بين النقاط الغير مُعينة بعد باستخدام Classify LAS Noise. نقاط الضوضاء تتوافق مع النقاط التي تكون على ارتفاعات أو انخفاضات غير طبيعية، وربما تكون نتيجة لأخطاء عشوائية في بيانات الليدار.

أولاً، يتم تصنيف النقاط التي تقع في ارتفاعات منخفضة بالنسبة لسطح الأرض، وذلك باستخدام معلمات محددة لتحقيق هذا الهدف:

- استخدام طريقة: الارتفاع النسبي من الأرض: يحدد هذا الاختيار النهج المستخدم لتصنيف الضوضاء استنادًا إلى الارتفاع النسبي بالنسبة لسطح الأرض.
- استخدام نموذج الارتفاع الرقمي (DTM) المستنتج سابقًا والذي سيتم استخدامه كسطح أرضي مرجعي لتصنيف الضوضاء.
- تم تحديد الارتفاع الأدنى: ٢- م ، حيث يُعتبر أي ارتفاع أقل من هذا الرقم نقطة شاذة.
- بالنسبة للارتفاع الأقصى: لم نحدده، لأننا سنستخدمه في خطوة لاحقة باستخدام طريقة أخرى لاستبعاد النقاط الشاذة التي يزيد ارتفاعها عن عتبة معينة.

ثانياً، يتم تصنيف النقاط التي تقع في ارتفاعات أعلى غير طبيعية بالنسبة لسطح الأرض لتحديد الضوضاء العالية، وهذه المرة باستخدام طريقة الارتفاع المطلق. ستصنف أي نقطة تكون ارتفاعها أعلى من ٨٠ مترًا كضوضاء عالية.

تتمتع المباني في منطقة الدراسة بارتفاع أقصى يبلغ حوالي ٧٧ مترًا، ولهذا السبب تقوم باختيار قيمة قصوى تبلغ ٨٠ مترًا. تم الحصول على هذه القيمة عن طريق استكشاف سحابة النقاط LAS.

نتيجة هاتين الخطوتين هو تصنيف بعض نقاط LAS كضوضاء منخفضة وضوضاء عالية.

• تصنيف نقاط المباني:

بعد تصنيف نقاط الضوضاء والنقاط الأرضية في سحابة الليدار وإيقاف تشغيلها، تم تصنيف نقاط المباني باستخدام أداة Classify LAS Building، والتي تعتمد على مجموعة من الطرق لتحديد نقاط المباني. يعتبر ضروريا فصل نقاط الأرض قبل تشغيل هذه الأداة. تقوم الأداة بتحديد الأسطح الصلبة من بين النقاط غير المُخصّصة، حيث يكون هناك عودة واحدة فقط لكل نبضة ليزر. على العكس من ذلك، قد تحتوي منطقة تحتوي على أشجار على عدة ارتدادات لكل نبضة ليزر بسبب وصول الضوء وانعكاسه من عدة طبقات في أوراق الأشجار.

تم استخدام المعلمات التالية لتحسين الأداء:

- الحد الأدنى لارتفاع السطح: ٢,٥ متر. الحد الأدنى للمساحة: ٢٠ متر مربع. (هاتين المعلمتين ضروريات للتأكد من أن السطح المنخفض جدا أو صغير جدا في المساحة لا يتم تصنيفه عن طريق الخطأ على أنه مبنى). تم اختيار قيمتهما بالتجربة والخطأ للحصول على الحد الأقصى من النقاط المصنفة بشكل صحيح كمباني، مع تقليل الإيجابيات الكاذبة وذلك في منطقة صغيرة من البيانات.
- طريقة التصنيف Aggressive: (تحدد طريقة التصنيف هذه ما إذا كان سيتم تصنيف النقاط كمباني بشكل متحفظ أو قوي.).

٧.٢.٦. استخلاص بصمة المباني:

الخطوة التالية هي استخدام نقاط LAS المصنفة كمباني لاستخراج أطُر المباني ثنائية الأبعاد (بصمة المباني). يظهر ذلك في الشكل (٨)، حيث يتم بداية توليد طبقة نقطي (Raster) تظهر مواقع

نقاط المباني استنادا إلى الكود رقم ٦ الذي يرمز إلى تصنيف المباني، كما هو موضح في الشكل (٩). في هذه الخطوة، يتم تحويل نقاط الليدار التي تحمل الكود رقم ٦ إلى خلايا طبقة نقطي (Raster) بدقة مكانية تبلغ ٠,٣ متر، في حين تأخذ باقي الخلايا قيمة معدومة (NoData).

الشكل (٨) عينة من نقاط الليدار المصنفة كمباني لاستخراج بصمات المباني

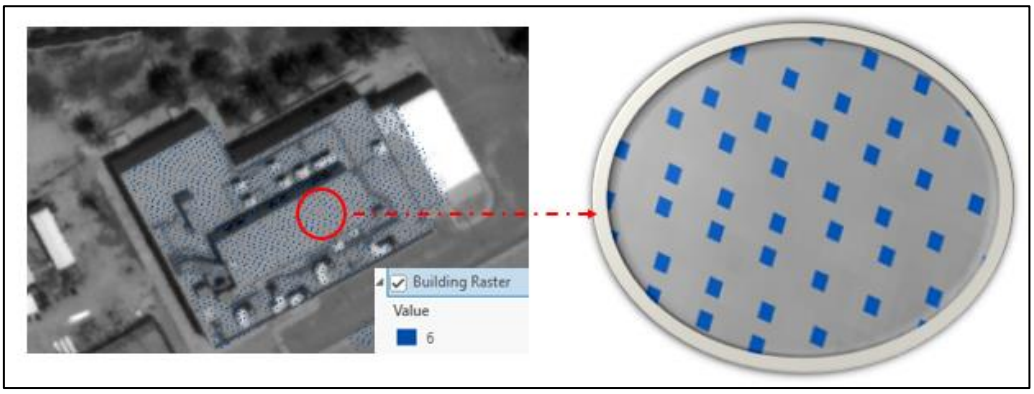

الشكل (٩) عينة من طبقة raster تظهر مواقع نقاط المباني

يظهر في الطبقة النقطية (Raster) السابقة الشكل العام للمباني بشكل واضح، ولكن البكسلات التي تشكل سطح المبنى غير متصلة بغالبها ومتباعدة مسافات متفاوتة ضمن ١ متر أو أكثر قليلا، وحدودها تظهر بشكل غير منتظم. أيضا، هناك بعض الأشكال الصغيرة جدا لتكون مباني حقيقية ويجب إزالتها. سيتم حل هذه المشكلات لاحقًا في سير العمل، ولكن أولاً، سيتم تحويل (Raster) المباني إلى

طبقة مضلعات. بعد ذلك ستطبق عمليات لاحقة لتنظيف المضلعات لإنشاء طبقة البيانات النهائية لأطُر المباني.

يوضح الشكل (١٠) عينة من طبقة مضلعات المباني الأولية غير المعالجة (Unprocessed_Buildings) بعد تحويلها من طبقة النقطي (Raster).

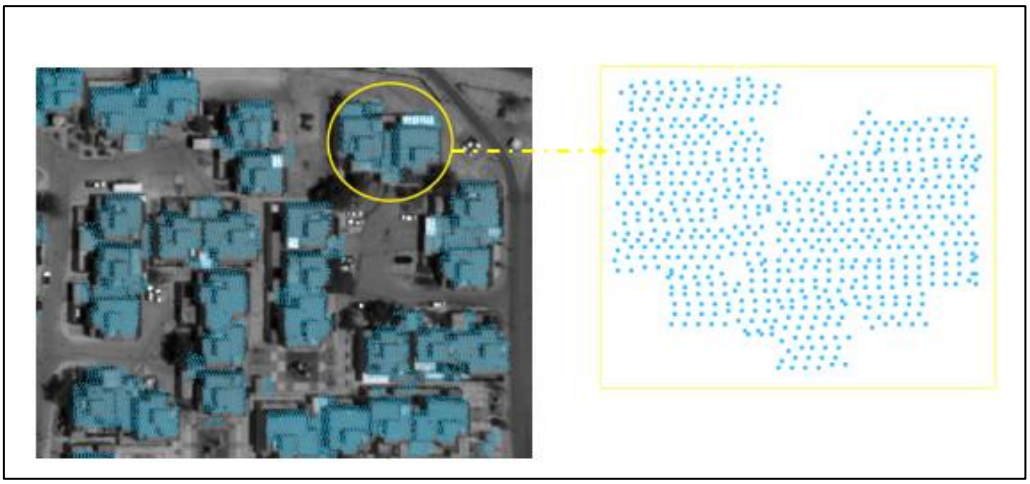

الشكل (١٠) عينة من طبقة مضلعات المباني الأولية

من الشكل ١٠ نلاحظ أن كل بكسل في النقطي (Raster) قد تم تحويله الى مضلع، وعندما يتجاور بكسلان أو أكثر، يتم دمجهم في مضلع واحد. ومع ذلك، فإن معظم المضلعات الناتجة التي تشكل سطح البناء غير متصلة، والمسافات بينها تقل عن ١ متر. ولذلك، تم اتباع سلسلة من الخطوات وفقا لخطة سير عمل موضحة في الشكل (١١)، لإنشاء الطبقة النهائية لبيانات بصمات المباني.

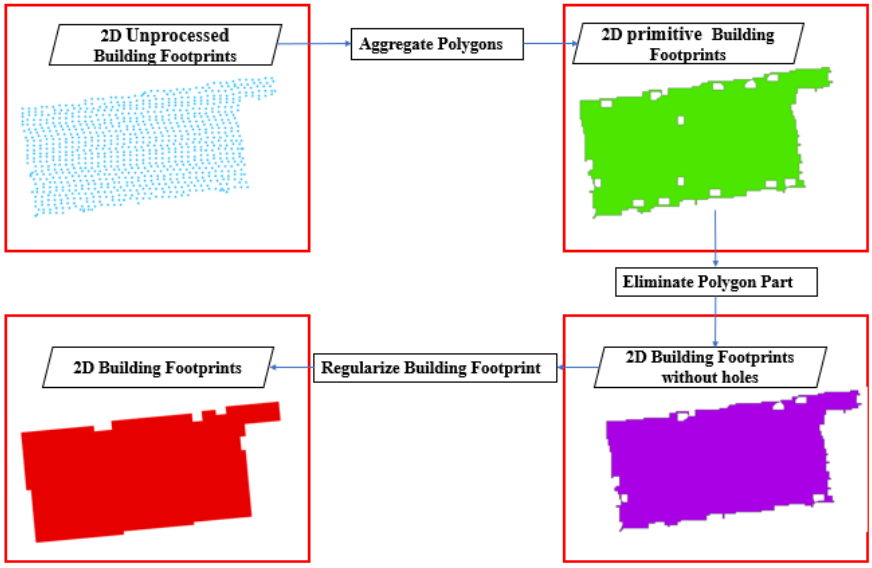

الشكل (١١) سير عمل معالجة المضلعات للحصول على طبقة بصمات المباني النهائية

تبدأ خطة سير العمل السابقة بتجميع المضلعات في طبقة الإدخال غير المعالجة ثنائية الأبعاد (D Unprocessed Building Footprints2) باستخدام أداة Aggregate Polygons. تقوم هذه الأداة بتجميع ودمج المضلعات المتجاورة التي تبعد عن بعضها مسافة تقل عن متر واحد. يكون الناتج طبقة الإخراج (D Primitive Building Footprints2) التي تحتوي على ٨٢٧٦ مضلعا، وتُمثل آثار سطح المبنى البدائية. يتم إزالة المضلعات ذات المساحة الأقل من ٢٥ مترًا (والتي بلغ عددها ٥٢٧١ مضلع)، حيث يُفترض أنها لا تمثل مبانٍ حقيقية، من عمليات المعالجة اللاحقة في سياق الخطة.

يُلاحظ أيضا وجود فجوات داخل المضلعات في هذه الطبقة. لذلك، يتم الانتقال إلى الخطوة التالية وهي إزالة هذه الفجوات باستخدام أداة Eliminate Polygon Part. حيث تم تحديد عتبة الدمج بمساحة ٦٠ مترا مربعًا، وذلك استنادًا إلى التجربة والخطأ (حيث يتم دمج أي فجوة تكون مساحتها ٦٠ مترًا مربعًا أو أقل مع المضلع الأساس).

تشمل المرحلة الأخيرة تنعيم حواف المضلعات باستخدام أداة Regularize Building Footprint، والتي تعتمد على طريقة الزوايا القائمة لإنشاء مبانٍ ذات زوايا نظيفة. بالنسبة لمعلمة التسامح (Tolerance)، فهي أقصى مسافة يمكن أن تحدها البصمة المنتظمة عن حدود الميزة الأصلية لها. يُعتبر اختيار ضعف حجم الخلية النقطية الأصلية تقريبا خيارا جيدا في معظم الحالات (Esri, 2024)، وفي دراستنا تم تعيينها ٠,٦ متر نظرا لأن حجم الخلية هو ٠,٣ متر. بالنسبة لمعلمة Densification، تُحدد هذه المعلمة الفاصل الزمني لأخذ العينات وتقييم ما إذا كانت الميزة المنتظمة مستقيمة أم منحنية وقيمتها مساوية أو أقل لقيمة التسامح. كما تم تحديد دقة الشبكة (Precision) بـ ٠,١٠ م بناءً على التجربة والخطأ، حيث تُمثل هذه القيمة دقة الشبكة المستخدمة في عملية التنظيم، وتتراوح عادة بين ٠,٠٥ و٠,٢٥.

لتقييم دقة طريقة استخلاص أسطح المباني من بيانات LiDAR، تم إجراء مقارنة هندسية بين ٣٠ مبنى عشوائيا تم رقمنتها من المرئية الفضائية عالية الدقة ونظيراتها المستخرجة من بيانات LiDAR باستخدام المعادلات الموضحة في القسم النظري.

تم فحص وتدقيق الطبقة الناتجة، وتم تحسين بصمات المباني يدويا في الحالات التي تستدعي ذلك، حيث كانت هناك عيوب صغيرة. تمت هذه العملية بعد إتمام عملية تقييم الدقة.

٧.٢.٧. تصنيف أنواع الأسطح في بيئة GIS:

لتصنيف أنواع الأسطح، تم الاستفادة من تحليل بيانات قيم شدة LiDAR. بدايةً، تم إنشاء طبقة (raster) تمثل قيم شدة LiDAR في منطقة الدراسة. بعد ذلك، تم تنعيم السطح باستخدام مرشح المتوسط (mean filter) لضمان تجانس قيم شدة السطح وعزل القيم الشاذة. يوضح الشكل طبقة قيم الشدة قبل وبعد تطبيق مرشح المتوسط.

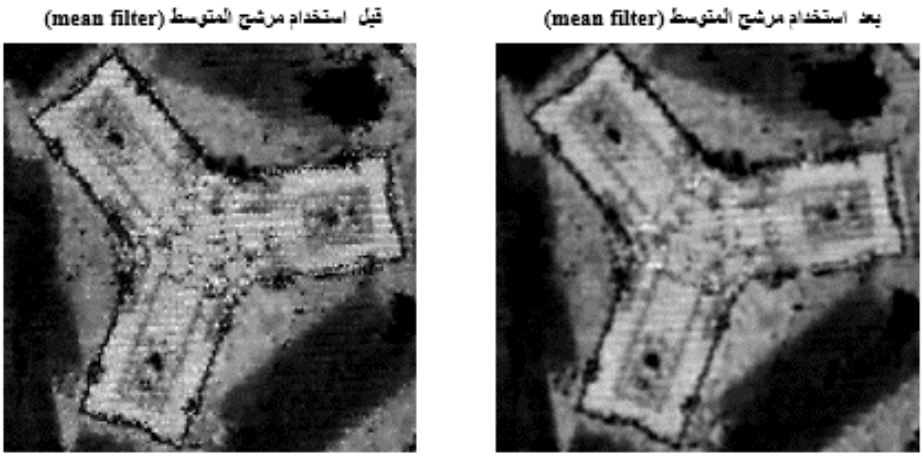

الشكل (١٢) سطح أحد المباني من طبقة قيم شدة LiDAR قبل وبعد تطبيق مرشح المتوسط (mean filter)

بعد تحسين طبقة قيم الشدة، تم استخراج القيم الإحصائية التالية: أعلى وأقل قيمة شدة لكل سطح بالإضافة لحساب متوسط قيم الشدة لكل سطح من أسطح المباني. تم ربط هذه القيم الإحصائية بطبقة أسطح المباني التي تم إنشاؤها في المرحلة السابقة. وأخيرا، تم تصنيف أنواع الأسطح بناءً على هذه القيم إلى أسطح خشنة وناعمة، وذلك بالاستعانة بعينات مرجعية تمثل أنواع الاسطح في منطقة الدراسة. وبما أن مجال اهتمامنا هو أسطح المباني، فقد تم دراسة قيم شدة الانعكاسية فيها لنتمكن فيما بعد من تصنيفها. تم استخدام ١٤٠ عينة من منطقة الدراسة الشكل ١٣، حيث شملت عدة أنواع من الأسطح:

- أسطح مباني ذات صبة جاهزة مع بحص (ملساء).
- أسطح مباني ذات صبة جاهزة مع بحص (خشنة).
- أسطح مباني ذات أسمنت عادي.
- أسطح مواقف ذات أسمنت عادي.
- أسطح مبلطة.
- صنف باقي الأسطح.

تم استخدام ٨٠ عينة من العينات المرجعية التي تم جمعها لعملية التصنيف، بينما تم استخدام ٦٠ عينة أخرى لتقييم واختبار عملية التصنيف وحساب دقة النتائج.

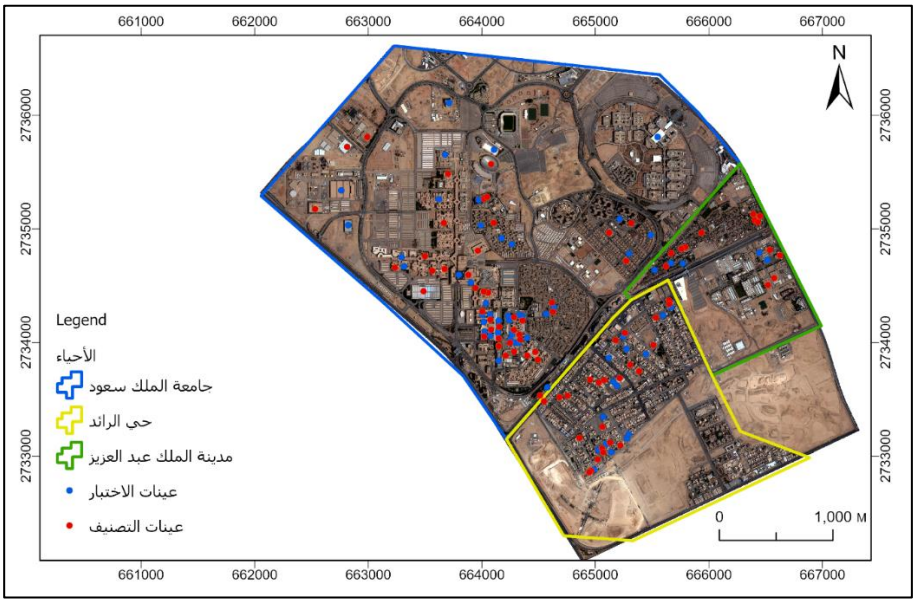

الشكل (١٣) التوزيع المكاني للعينات المرجعية الأرضية (عينات التصنيف والاختبار)

يوضح الشكل (١٤) سير عمل معالجة بيانات الليدار لاستخلاص أسطح المباني وأنواعها في بيئة GIS.

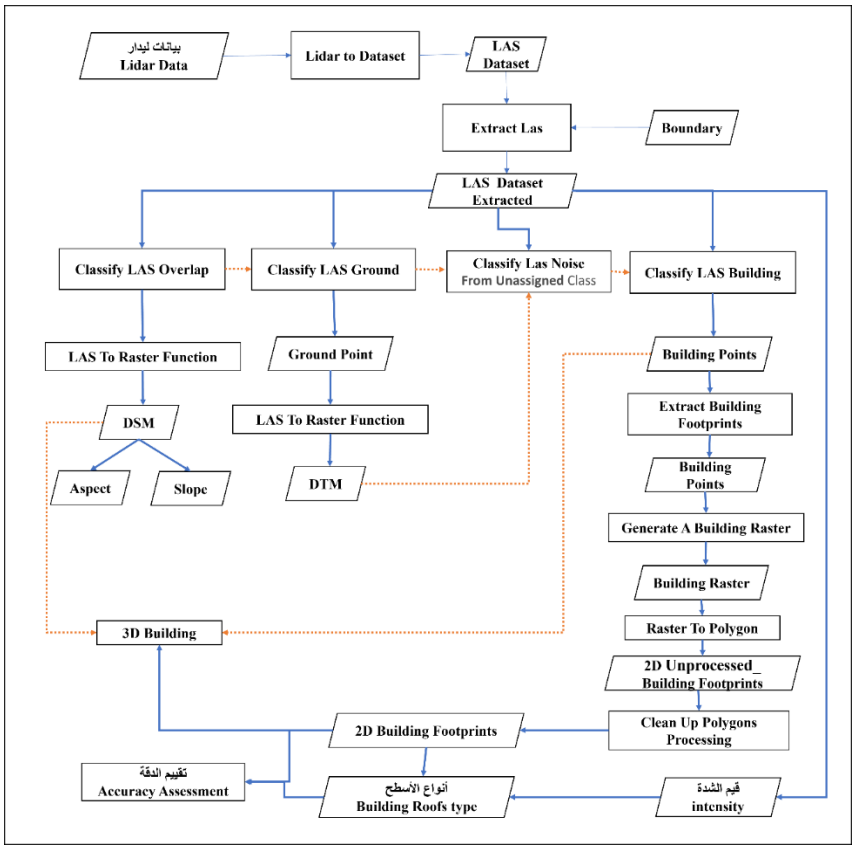

الشكل (١٤) سير عمل معالجة بيانات الليدار لاستخلاص أسطح المباني وأنواعها في بيئة GIS

٧.٣. التصنيف الهدفي لاستخلاص أسطح المباني وأنواعها من بيانات الليدار:

٧.٣.١. التصنيف الهدفي لاستخلاص أسطح المباني:

- في المرحلة الأولى: تم تجميع الطبقات المختلفة بعد تنضيدها في نفس المكان. شملت هذه الطبقات: nDSM، Intensity، slope، وطبقة (aspect)، حيث تم تحسين عرضها لتوفير أفضلية في التمييز بين المعالم.
- في المرحلة الثانية: تم تجزئة الصورة، الشكل (١٥)، باستخدام معاملات محددة بعناية، بناءً على الدراسات السابقة ذات الصلة واعتماد مبدأ التجربة والخطأ. تم استخدام أسلوب التجزئة "multiresolution segmentation" بمعاملات محددة كالتالي: المقياس: ٤٠، الشكل Shape:0.2، التركّز (الاكتناز) Compact:0.5. تم إعطاء أوزان محددة لكل طبقة في عملية التجزئة، حيث تم منح الوزن ٥ للطبقة nDSM ووزن ٣ للطبقة Intensity، ووزن ٢ للطبقة slope، بينما تم منح الطبقة aspect وزن ١.

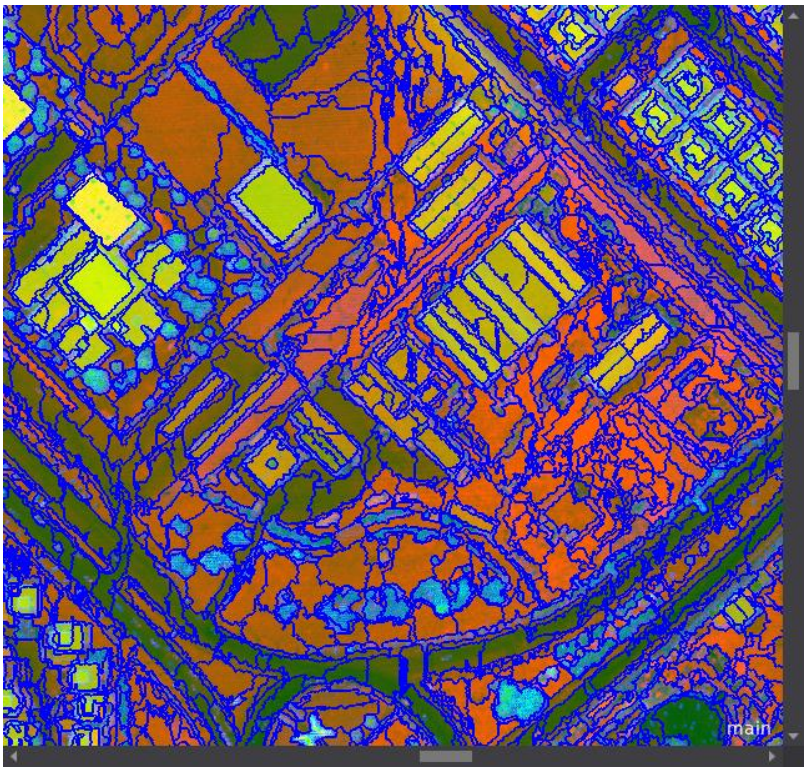

الشكل (١٥) التجزئة (معامل المقياس = ٤٠، الشكل = ٠.٢، الاكتناز = ٠.٥) لجزء من منطقة الدراسة باستخدام بيانات الليدار

شملت المرحلة الأخيرة عملية التصنيف الى فئتين : فئة أسطح مباني وفئة الخلفية حيث تم تطوير وتطبيق مجموعة من قواعد القرار "decision rules"، الشكل (١٦). تُستخدم هذه القواعد لتعريف خصائص أسطح المباني وتمييزها عن فئة الخلفية في الصورة. يتم تعريف السمات عن طريق إنشاء

قواعد تستند إلى خصائص الهدف مثل المكانية، والطيفية، والنسيجية. يتم تحديد السمات استناداً إلى المعرفة البشرية حول أنواع السمات المختلفة. على سبيل المثال، يمكن تلخيص خصائص أسطح المباني، على سبيل المثال لا الحصر، كالتالي: تتميز أسطح المباني بقيم nDSM أكبر من ٢,٥ متر، تكون أشكال أسطح المباني قريبة من المستطيل،..الخ. يمكن أن تكون هذه القواعد كافية للتمييز بين فئة أسطح المباني وفئة الخلفية في الصورة المجزأة وفقا لمنطقة الدراسة.

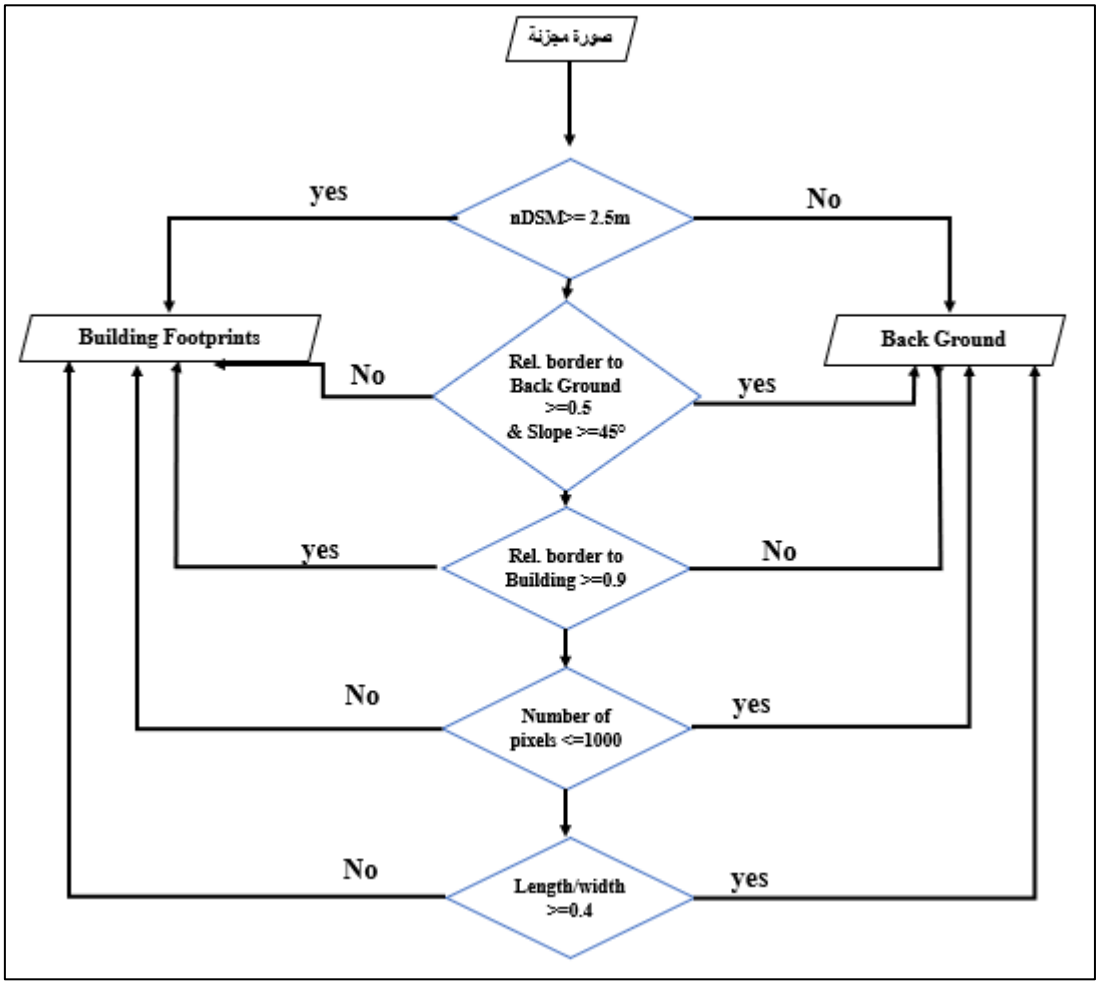

الشكل (١٦) مخطط قواعد القرار لاستخلاص أسطح المباني من بيانات الليدار

٧.٣.٢. التصنيف الهدفي لاستخلاص أنواع الأسطح المباني:

بعد الحصول على فئتين وهما فئة أسطح المباني وفئة الخلفية، سيتم تصنيف فئة الأبنية إلى ستة أنواع من الأسطح باستخدام ٨٠ عينة من البيانات التدريبية. تم اختبار ثلاث خوارزميات مختلفة وهي آلة دعم المتجهات (SVM)، شجرة القرار (DT)، والغابة العشوائية (RT) لاستخلاص أنواع أسطح المباني من بيانات الليدار. يُظهر الشكل (١٧) منهجية العمل للتصنيف الهدفي لبيانات الليدار ضمن برنامج eCognition.

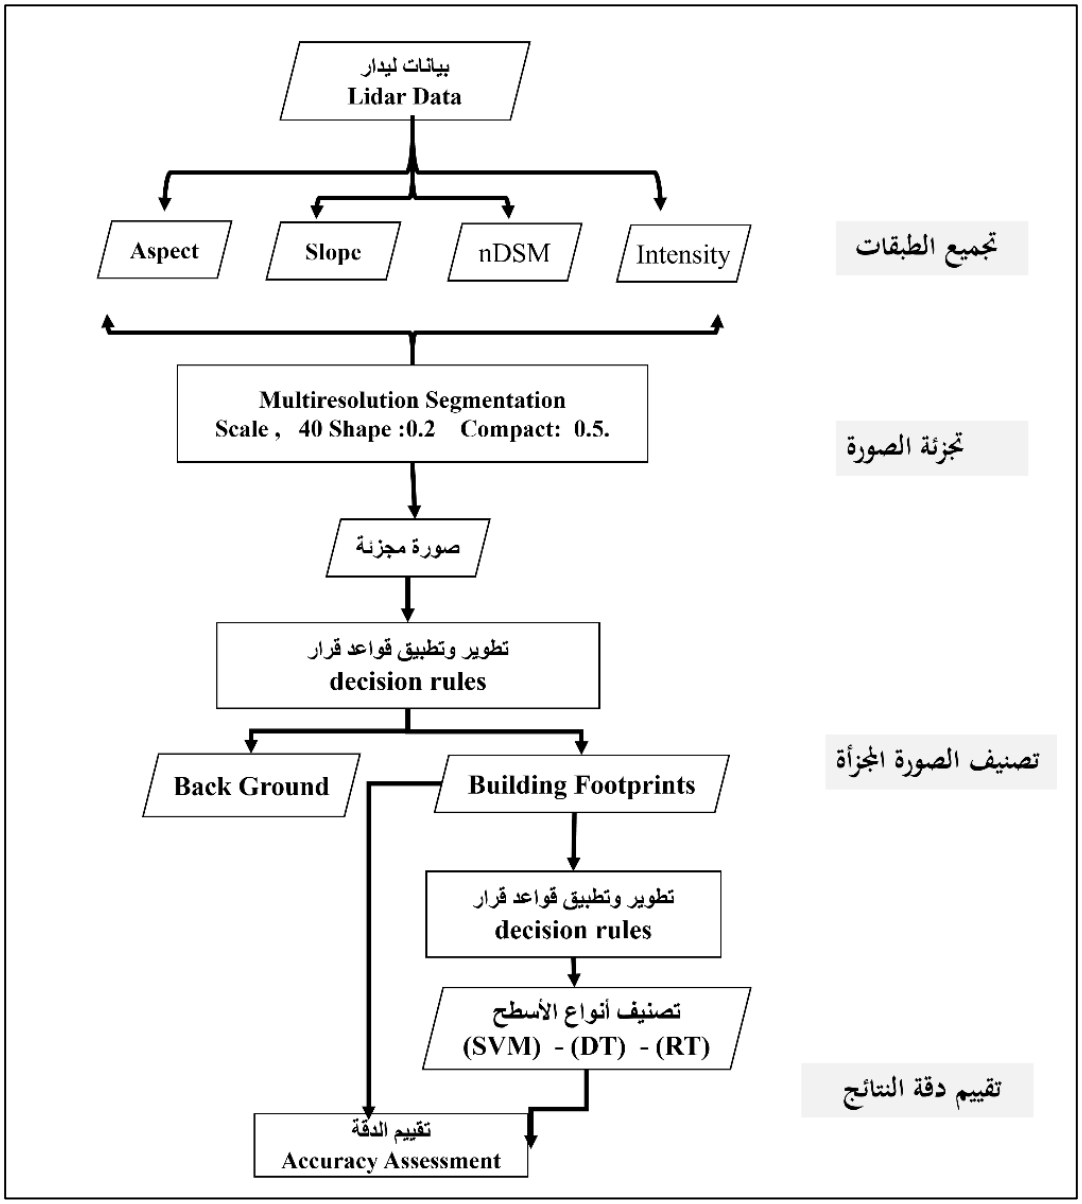

الشكل (١٧) منهجية العمل للتصنيف الهدفي لبيانات الليدار

بعد استخراج فئة أسطح المباني وأنواعها ضمن برنامج eCognition، تم تصديرها إلى برنامج ArcGIS Pro لإجراء بعض المعالجات الجغرافية وتقييم دقة النتائج.

٨. النتائج والمناقشة:

٨.١. نتائج معالجة بيانات الليدار في بيئة GIS:

٨.١.١. النموذج الرقمي للسطح (DSM):

تم تمثيل النموذج الرقمي للسطح (DSM) المستخرج بواسطة بيانات الليدار كما هو موضح في الشكل (١٨)، حيث يتراوح نطاق القيم بين ٥٧٣,٩٤ و٨٧٥,٧٣ متر. يُظهر النموذج الرقمي للسطح

للمدينة تفاصيل التضاريس، بما في ذلك ارتفاع المباني والأشجار والعناصر الأخرى. المناطق الفاتحة على الخريطة ترمز إلى المناطق ذات الارتفاع الأعلى، في حين تشير المناطق الداكنة إلى الأماكن ذات الارتفاع الأقل. توضح الخريطة أيضًا بعض الشوارع ومعالم المدينة. يُظهر هذا النموذج الرقمي للسطح بشكل واضح توزيع الارتفاعات في المنطقة، ويقدم رؤية شاملة لتضاريس المدينة وعناصرها المختلفة. كما يتضح من الشكل أن معظم مباني جامعة الملك سعود تظهر بارتفاعات أكبر بالمقارنة مع باقي المباني في حي الرائد ومدينة الملك عبد العزيز للعلوم والتقنية باستثناء مبنى "البرج"، الذي يعتبر أعلى مبنى في مدينة الملك عبد العزيز للعلوم والتقنية.

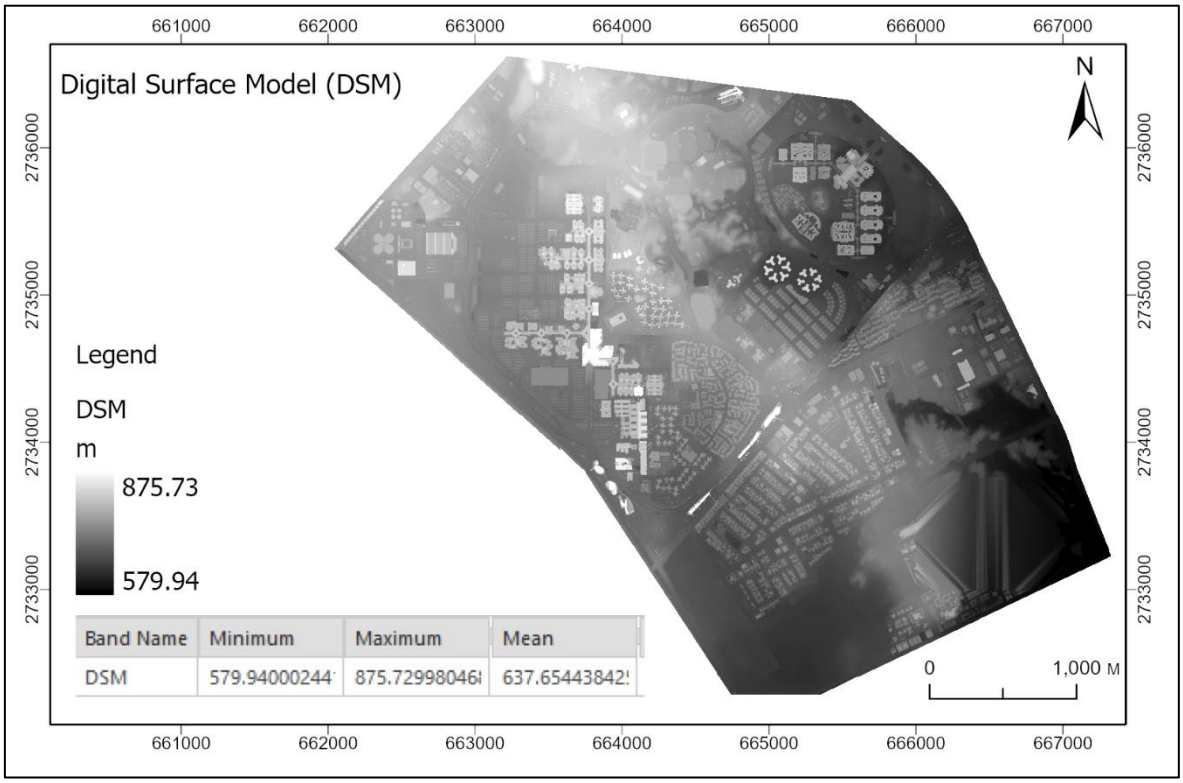

الشكل (١٨) النموذج الرقمي للسطح (DSM) لمنطقة الدراسة

٨.١.٢. خريطة الانحدار Slope من DSM:

تم حساب خريطة الانحدارات من النموذج الرقمي للسطح (DSM) السابق، كما هو موضح في الشكل (١٩)، حيث يتراوح نطاق القيم بين ٠ درجة و٨٩.٧٤ درجة. يُظهر الخريطة حواف المباني والأشجار والعناصر الأخرى من خلال اللون الداكن الذي يدل على الانحدار الكبير، المناطق الفاتحة على الخريطة ترمز إلى المناطق ذات الانحدار المنخفض، في حين تشير المناطق الداكنة إلى المناطق ذات الانحدار الكبير.

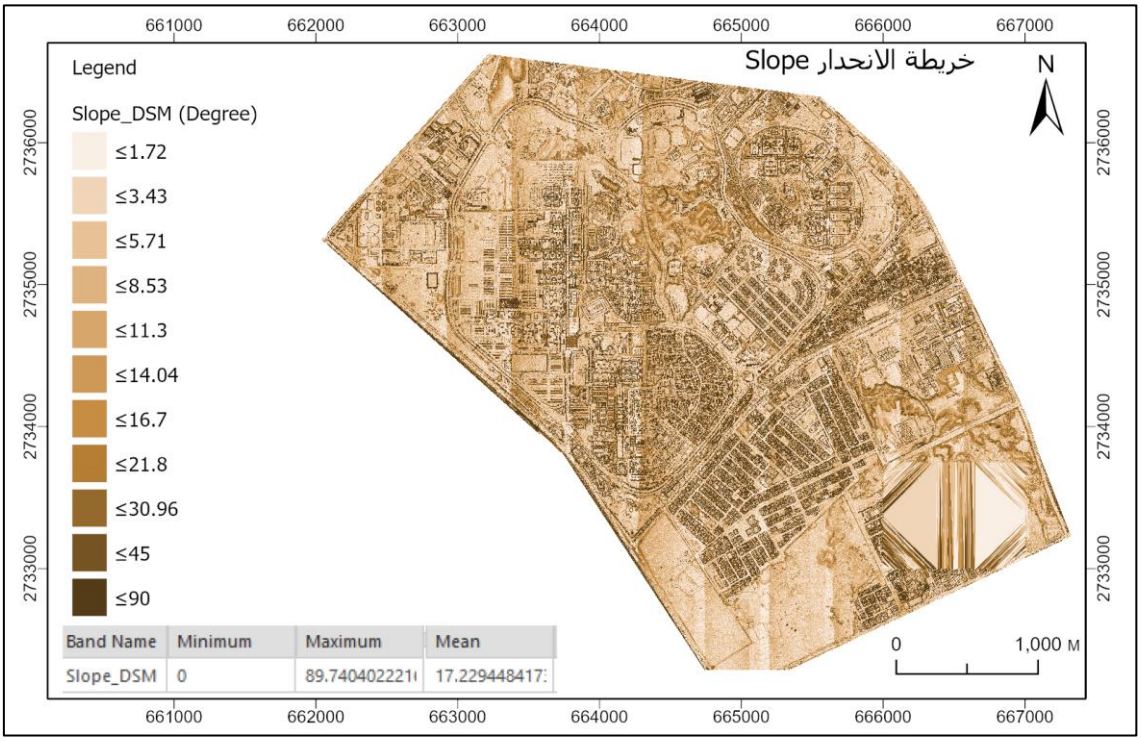

الشكل (١٩) خريطة الانحدار Slope لمنطقة الدراسة

٨.١.٣. خريطة الاتجاه Aspect من DSM:

كما تم حساب خريطة الاتجاه Aspect من النموذج الرقمي للسطح (DSM) السابق، كما هو موضح في الشكل ٢٠، يمكن ان تفيد هذه الخريطة في استخراج الاسطح المائلة في حالة وجودها.

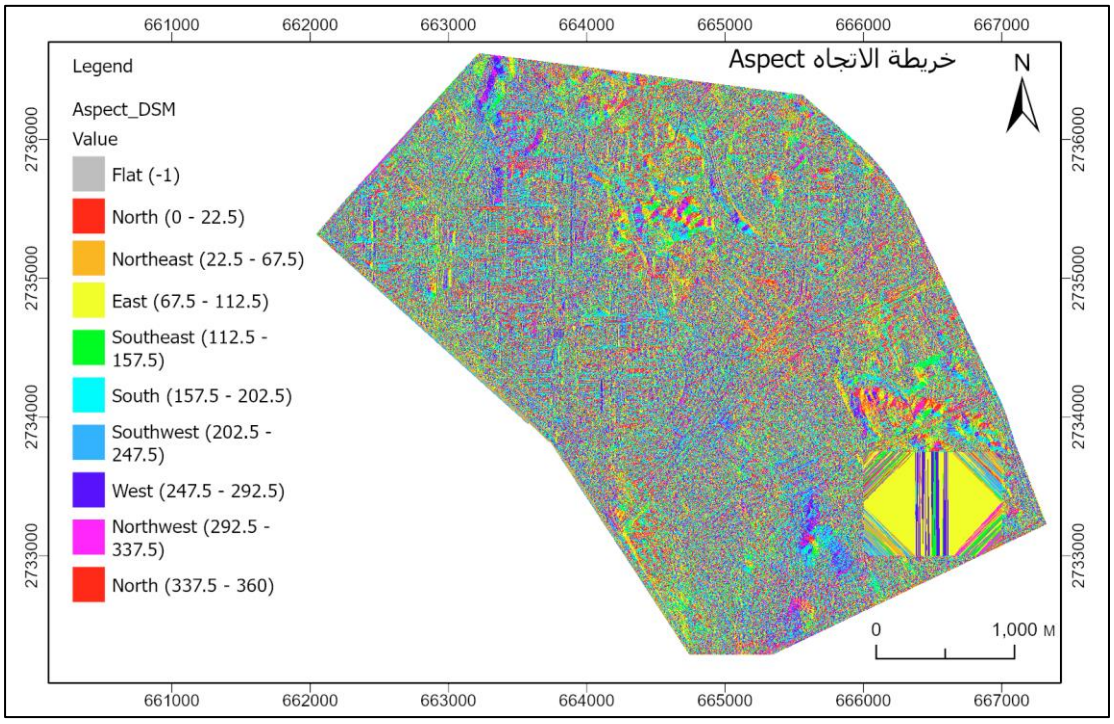

الشكل (٢٠) خريطة الاتجاه Aspect لمنطقة الدراسة

٨.١.٤. تصنيف نقاط الأرض:

بلغ عدد النقاط المصنفة كأرض طبيعية في السحابة LiDAR 9858868 (تسعة ملايين وثمانمائة وثمانية وخمسون ألفا وثمانمائة وثمانية وستون) نقطة. يُظهر هذا الرقم حجم البيانات الكبير التي تمثل الأرض الطبيعية في المنطقة المدروسة. وانطلاقا منها سوف نستخرج نموذج DTM.

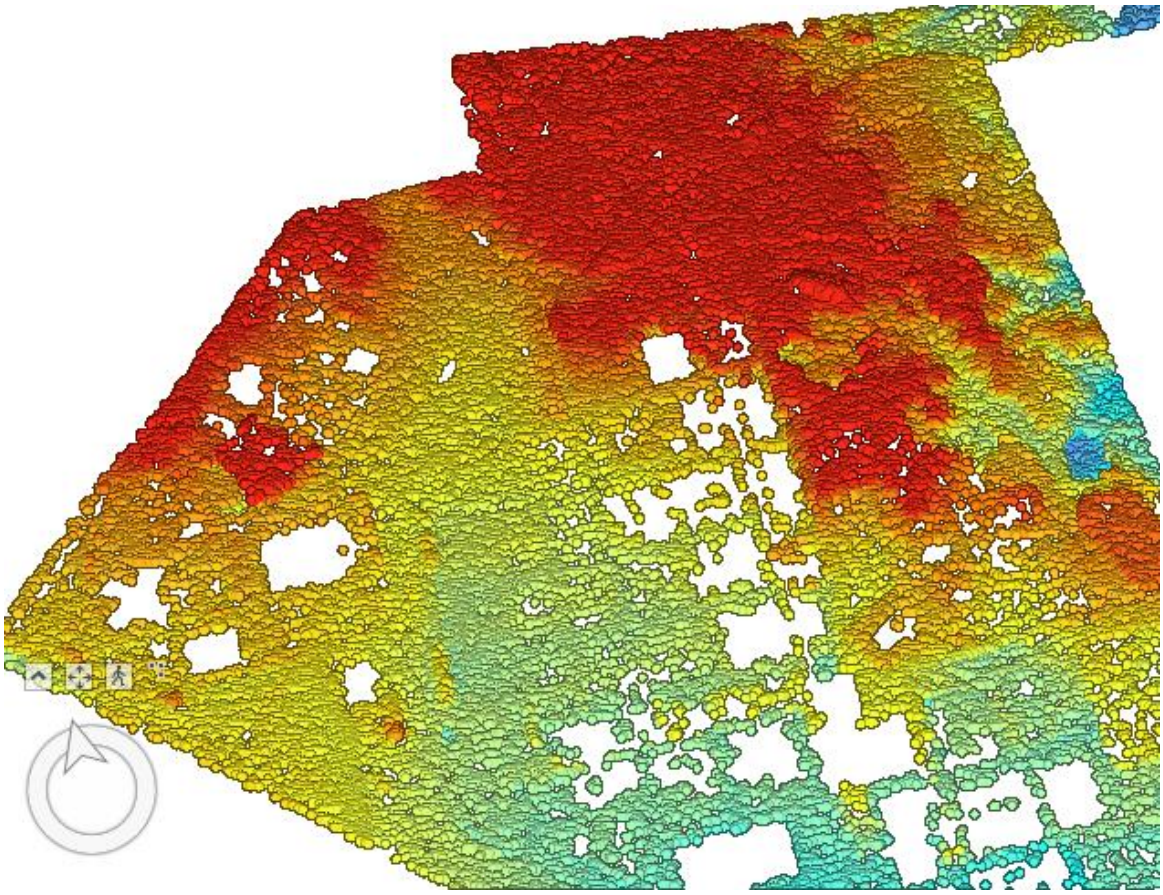

الشكل (٢١) جزء من سحابة النقاط LiDAR المصنفة كأرض طبيعية

٨.١.٥. نموذج DTM:

تم تمثيل النموذج الرقمي للتضاريس (DTM) المستخرج من بيانات الليزر الجوي كنقاط أرض طبيعية، كما هو موضح في الشكل (٢٢)، حيث تتراوح قيم الارتفاع بين ٦٠٥,٢٨ و٦٧٢,٣٩ متر. يعرض النموذج الرقمي للتضاريس تفاصيل الطبوغرافيا الطبيعية للمنطقة المدروسة. تُظهر المناطق الفاتحة (اللون الأبيض على الخريطة) المناطق ذات الارتفاع الأعلى، في حين تشير المناطق الداكنة (اللون الأخضر) إلى المناطق ذات الارتفاع الأقل. يتضح من الخريطة أن المنطقة المدروسة تتميز بارتفاعات منخفضة في الجهات الجنوبية والشرقية والجنوب الغربي، بينما يتمركز الارتفاع الاعلى في الشمال وبعض مناطق الوسط.

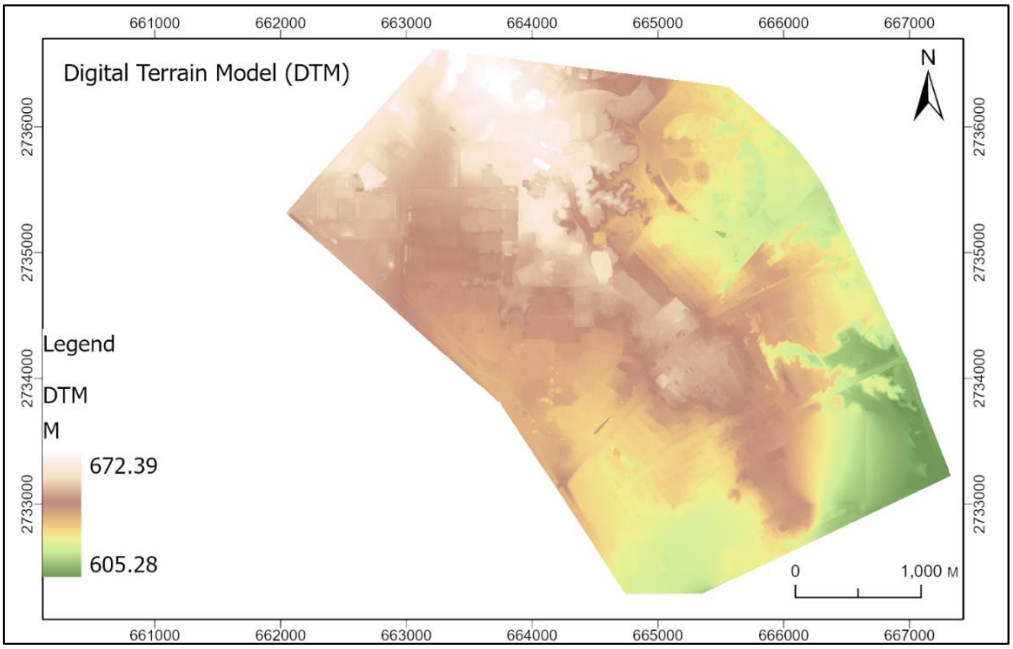

الشكل (٢٢) نموذج DTM لمنطقة الدراسة

٨.١.٦. النقاط الشاذة:

يُظهر الشكل (٢٣) النقاط التي تظهر على ارتفاعات أو انخفاضات غير طبيعية نتيجة لأخطاء عشوائية في بيانات الليدار. حيث يمثل النقاط المصنفة التي تقع في ارتفاعات منخفضة بالنسبة لسطح الأرض (أقل من −٢ متر) وبلغ عددها ٣٧٦ نقطة. كما يُمثل النقاط المصنفة و التي تقع في ارتفاعات تزيد عن ٨٠ مترًا كضوضاء عالية والتي بلغ عددها ١٤٧ نقطة.

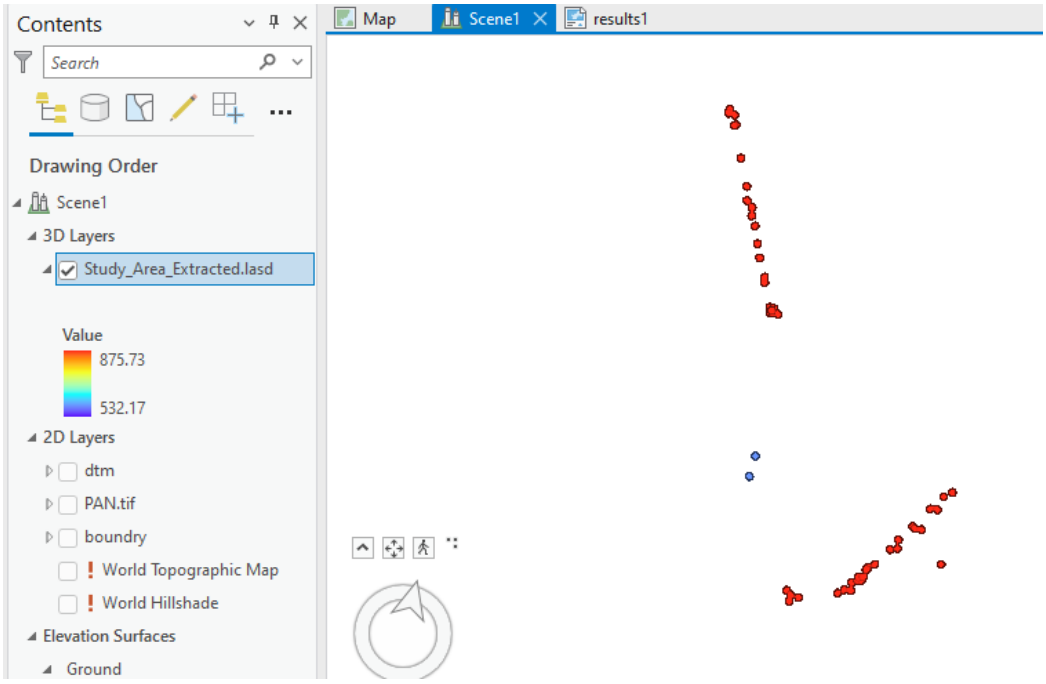

الشكل (٢٣) عينة من نقاط الليدار الشاذة في منطقة الدراسة

٨.١.٧. نقاط المباني:

تم تصنيف نقاط المباني من النقاط غير المعينة حيث يلغ عددها ٢٥٤٥١٦٨ (مليونان وخمسمائة وخمسة وأربعون ألفا ومائة وثمانية وستون) نقطة. يُظهر الشكل (٢٣) عينة من نقاط المباني المصنفة.

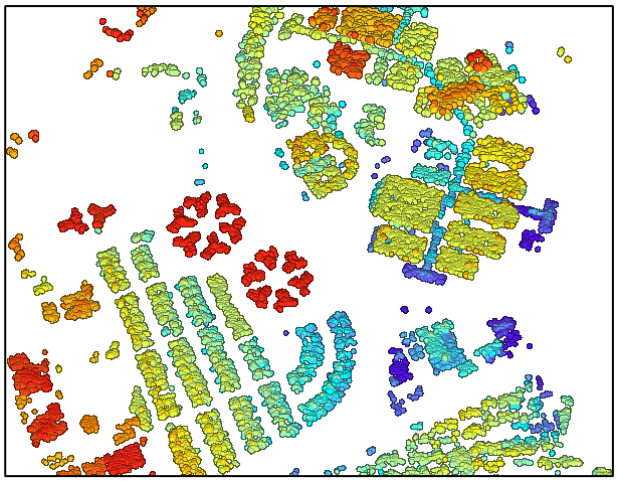

الشكل (٢٤) عينة من نقاط الليدار المصنفة كنقاط مباني

٨.١.٨. بصمة المباني (D2) في منطقة الدراسة:

يظهر الشكل (٢٥) طبقة raster (MB121.49) التي توضح مواقع نقاط المباني والتي تم تحويلها من نقاط الليدار. لاحظنا وجود عدد من أسطح المباني والمواقف والمنشآت الأخرى التي لم تظهر في الصورة، والسبب في ذلك هو أن بيانات ليدار تعود إلى عام ٢٠١٢ (حيث لا يوجد بيانات ليدار حديثة)، بينما المرئية حديثة وتعود لعام ٢٠٢٢.

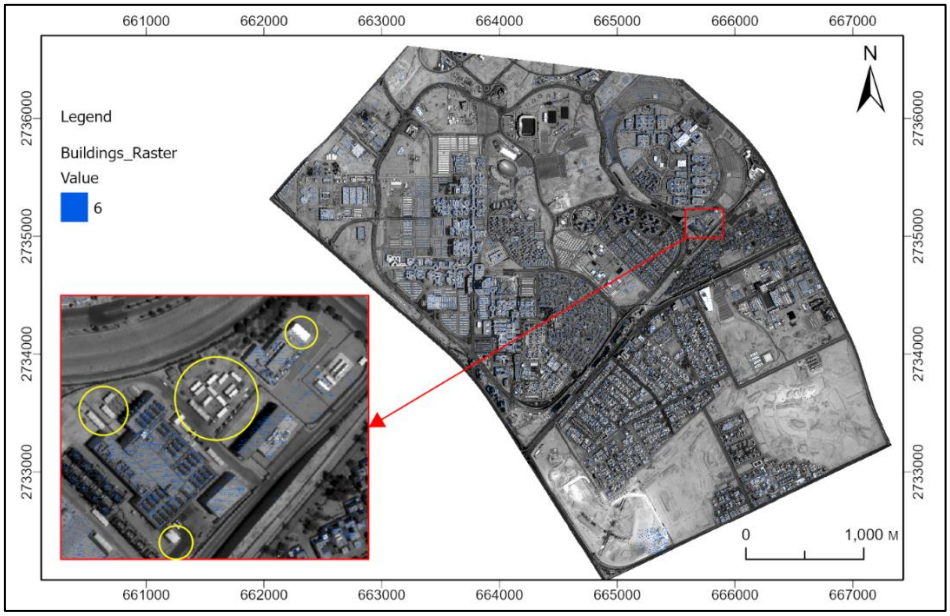

الشكل (٢٥) طبقة raster تظهر مواقع نقاط المباني

كما يُظهر الشكل (٢٦) طبقة المضلعات التي تمثل بصمات المباني والتي تم استخلاصها من بيانات الليدار (قبل التعديل اليدوي)، والتي تم الحصول عليها بعد سلسلة من عمليات المعالجة المكانية للنقطي (Raster) السابق، والتي تم شرحها سابقا في فصل المنهجية.

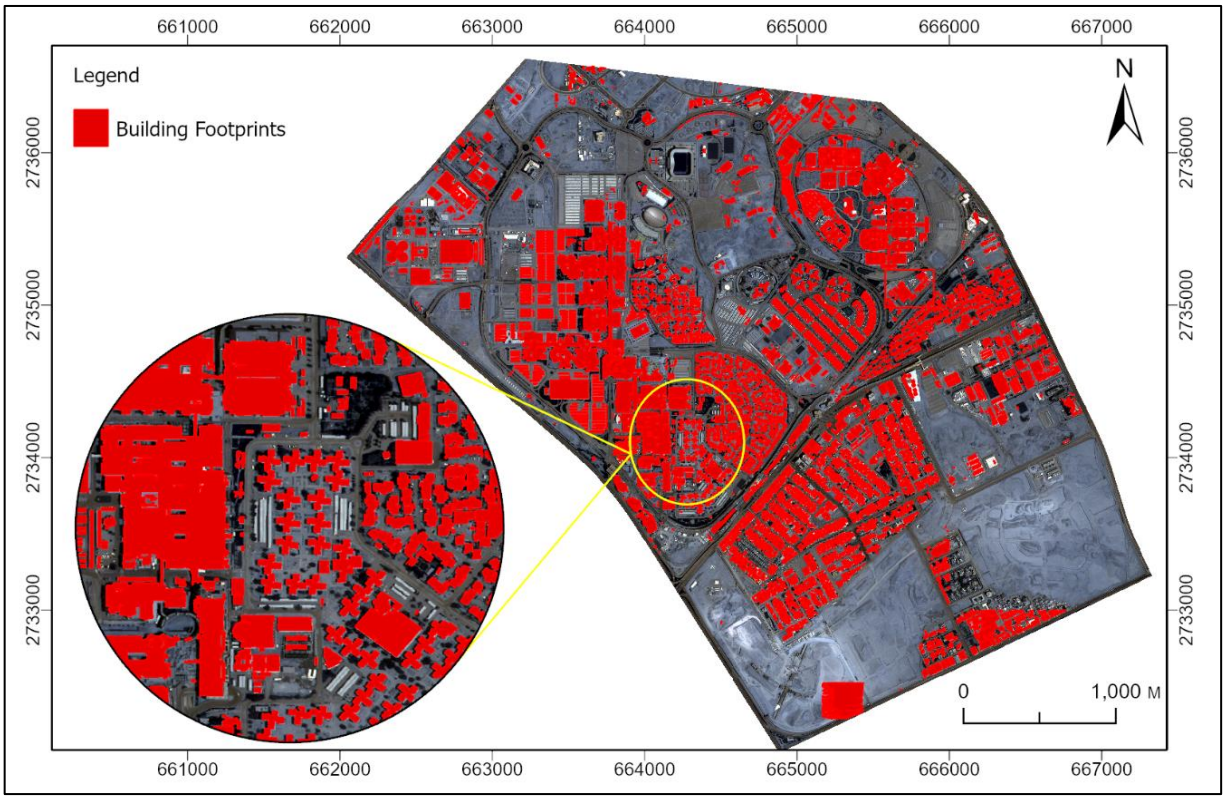

الشكل (٢٦) طبقة مضلعات أسطح المباني في منطقة الدراسة

من خلال الجدول الوصفي لطبقة المضلعات السابقة، وجدنا أن عدد المضلعات الإجمالي هو ٣٠٠٥ مضلعا، حيث تبلغ مساحة أصغر مضلع ٢٧,٧٣ متر مربع، ومساحة أكبر مضلع تصل إلى ٣٥٣٢٠٨,٩٣ متر مربع. يُلاحظ أن هذا المضلع يتألف من مجموعة من كتل البناء المتصلة ببعضها بواسطة ممرات مغلقة او مفتوحة، ويمتد داخل حرم جامعة الملك سعود. كما يبلغ متوسط مساحة المضلعات ٦٨١,٣ متر مربع.

تعتبر طبقة المضلعات السابقة، التي تم الحصول عليها من بيانات الليدار، النتيجة النهائية. وسيتم لاحقا تقييم دقة استخراج أسطح المباني من هذه البيانات بناءا على هذه الطبقة. بعد عملية التقييم، سيتم إجراء تعديلات يدوية على المضلعات التي تحتاج إلى تصحيح، أو حذف المضلعات التي لا تمثل أسطح المباني أو المواقف، بهدف الحصول على الطبقة النهائية القابلة للاستخدام.

٨.١.٩. تصنيف أنواع أسطح المباني في بيئة GIS من بيانات الليدار:

٨.١.٩.١. سطح قيم شدة بيانات الليدار:

يوضح الشكل (٢٧) سطح قيم شدة بيانات الليدار في منطقة الدراسة. نلاحظ من هذا الشكل أن قيم شدة بيانات ليدار في منطقة الدراسة تقع في المجال بين ٠ و٢٥٥، غير ان الغالبية العظمى من البكسلات تملك قيم شدة تقع بين ٦٠ و١٦٠. تمثل القيم الصغيرة الانعكاسية المنخفضة، وبالتالي تشير إلى الأسطح الخشنة. بينما تمثل القيم المرتفعة الانعكاسية العالية، أي الأسطح الملساء أو الناعمة.

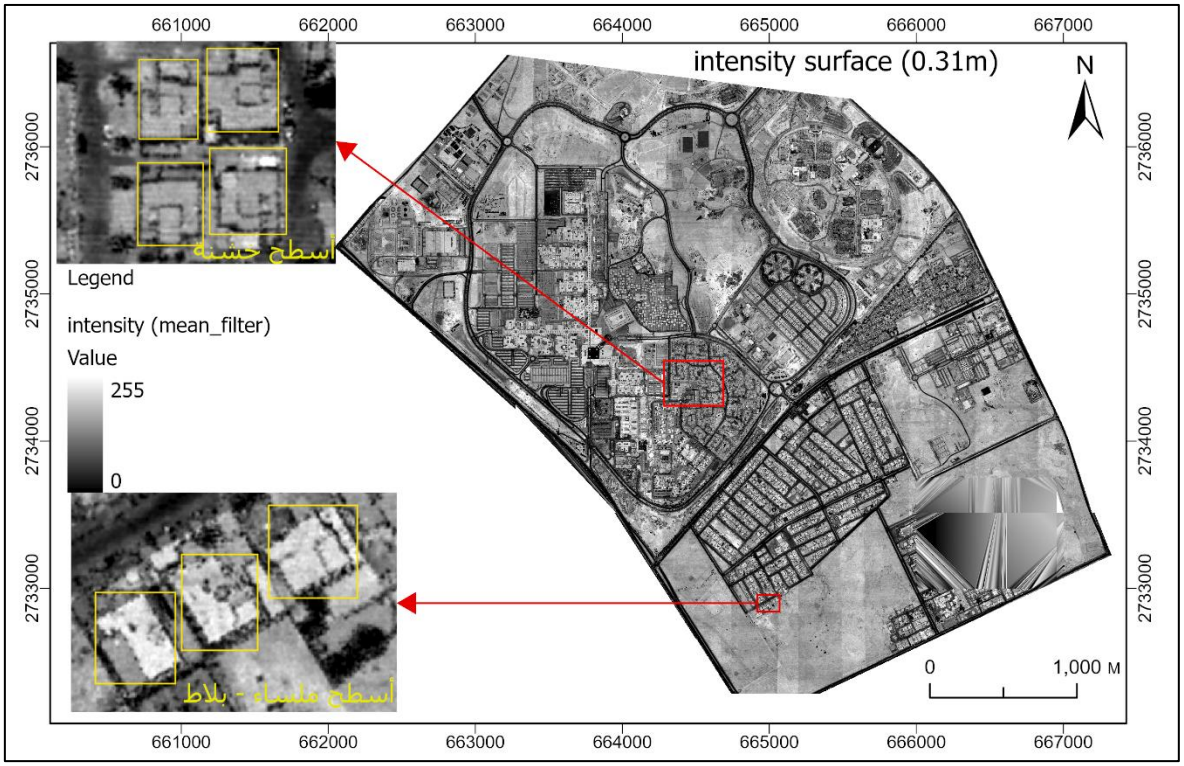

الشكل (٢٧) سطح قيم شدة بيانات الليدار في منطقة الدراسة

٨.١.٩.٢. تصنيف أنواع أسطح المباني:

بناءً على متوسط قيم شدة انعكاسية بيانات ليدار، تم تصنيف أنواع أسطح المباني إلى ثلاث أصناف رئيسية، الشكل (٢٨): صنف للانعكاسية المنخفضة (٠-١٠٠)، صنف للانعكاسية المتوسطة (١٠٠-١٢٥)، وصنف للانعكاسية العالية (١٢٥-١٧٥)، يُمثل هذا التصنيف المستوى الأول من عملية التصنيف، كما هو موضح في الشكل (٢٨). تتميز الأسطح الخشنة بقيم شدة انعكاسية بيانات ليدار منخفضة، بينما تتميز الأسطح الملساء بقيم شدة انعكاسية بيانات ليدار مرتفعة.

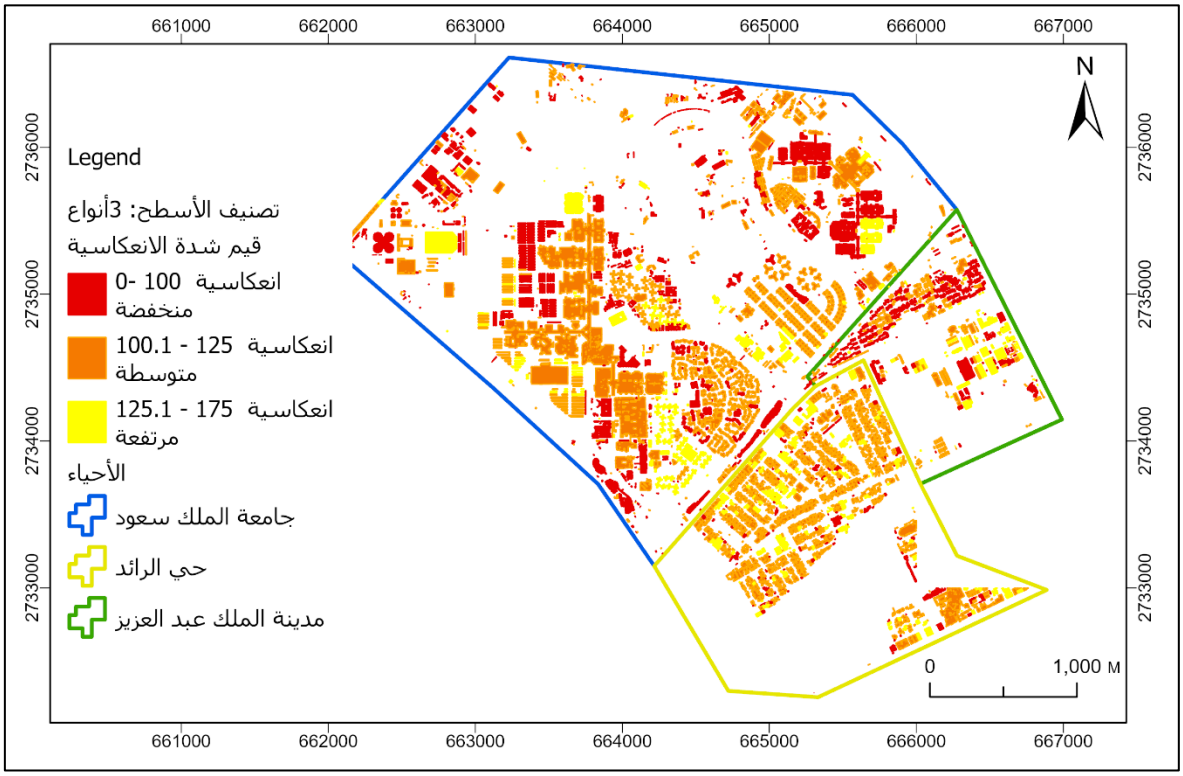

الشكل (٢٨) تصنيف أسطح المباني إلى ثلاثة أصناف رئيسية بناءً على قيم شدة انعكاسية بيانات ليدار في بيئة GIS

من خلال تحليل الشكل السابق، توصلنا الى الاستنتاجات التالية:

- أكثر من ٥٠٪ من أسطح جامعة الملك سعود هي أسطح متوسطة الانعكاسية و ٢٥٪ هي أسطح ذات انعكاسية المنخفضة (أسطح خشنة) و ٢٥٪ هي أسطح ذات انعكاسية عالية (أسطح ملساء)
- أغلبية الأسطح في حي الرائد هي أسطح متوسطة الانعكاسية ووجود بعض الاسطح ذات انعكاسية عالية (أسطح ملساء).
- أغلبية الأسطح في مدينة الملك عبد العزيز هي أسطح خشنة.
- تمتلك بعض الأسطح نفس شدة انعكاسية بيانات ليدار، على الرغم من كونها أنواعا مختلفة من الأسطح.

من السلبيات التي ظهرت أثناء التصنيف هو أن بعض الأسطح تم تصنيفها على أنها خشنة في حين أنها في الواقع ملساء. يرجع ذلك إلى أن قيمة شدة بيانات LiDAR لهذه الأسطح الخشنة كانت قريبة من عتبة التصنيف. ومع ذلك، سيؤدي تغيير عتبة التصنيف إلى تغيير كبير في تصنيف الأسطح الأخرى. لاختيار عتبة تصنيف مثلى، يجب إجراء أخذ عينات أرضية وتصنيفها بعد ذلك. يمكن اعتبار هذا كقيد من قيود الاعتماد على بيانات LiDAR في تصنيف أنواع الأسطح.

كما لاحظنا أيضا من الشكلين السابقين، أن نصف المباني في الجامعة وأغلبية الأسطح في حي الرائد تم تصنيفها كأسطح متوسطة الانعكاسية، على الرغم من أن أسطح الجامعة هي من نوع صبة جاهزة مع بحص وأسطح حي الرائد في أغلبها هي مبلطة. بمعنى آخر، تُظهر هذه الحالة قيدا آخر في استخدام بيانات LiDAR لتصنيف أنواع الأسطح، حيث أن بيانات LiDAR وحدها قد لا تكون كافية لتصنيف أنواع الأسطح بدقة.

من أجل تصنيف أسطح المباني من المستوى الثاني، والذي يشمل ستة أنواع رئيسية مذكورة سابقا في المنهجية، تم البدء بدراسة متوسط شدة انعكاسية بيانات الليدار لعينات من كل نوع من أنواع التصنيف كما هو موضح في الشكل (٢٩). يهدف هذا التحليل إلى: تصنيف الأسطح حسب متوسط شدة انعكاسية بيانات ليدار لكل عينة، وتحديد مدى تداخل شدة انعكاسية البيانات بين أنواع الأسطح المختلفة.

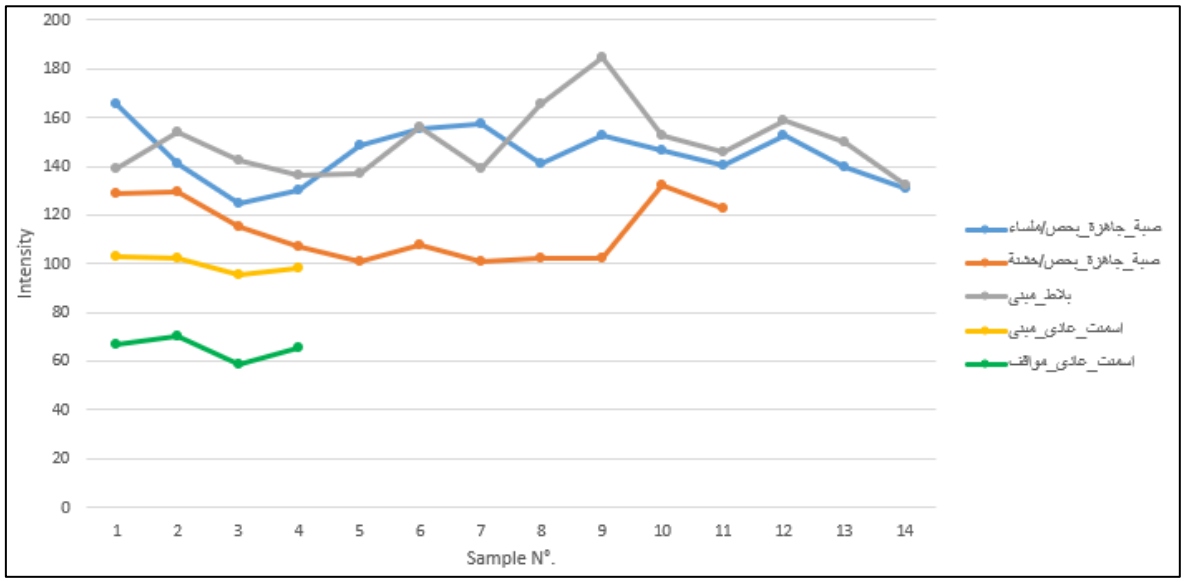

الشكل (٢٩) متوسط شدة انعكاسية بيانات الليدار لعينات التصنيف

مكننا الشكل (٢٩) من دراسة التداخل بين أنواع الأسطح حسب ما يلي:

- الصبة الجاهزة مع البحص (ملساء) والأسطح المبلطة: يُظهر الشكل تداخلا واضحا بين منحني متوسط شدة انعكاسية بيانات ليدار لعينات أسطح الصبة الجاهزة مع البحص (ملساء) ومنحني متوسط شدة انعكاسية بيانات ليدار لعينات أسطح البلاط. تتراوح متوسط شدة انعكاسية بيانات ليدار لعينات أسطح الصبة الجاهزة مع البحص (ملساء) بين ١٢٥ و١٦٥، بينما تتراوح متوسط شدة انعكاسية بيانات ليدار لعينات أسطح البلاط بين ١٢٨ و١٨٥.

- الصبة الجاهزة مع البحص (خشنة) والصبّة ذات الأسمنت العادي: لا يُظهر الشكل أي تداخل بين منحني متوسط شدة انعكاسية بيانات ليدار لعينات أسطح الصبة الجاهزة مع البحص (خشنة) ومنحني متوسط شدة انعكاسية بيانات ليدار لعينات أسطح الصبة ذات الأسمنت العادي. تتراوح متوسط شدة انعكاسية بيانات ليدار لعينات أسطح الصبة الجاهزة مع البحص (خشنة) بين ١٠١ و١٢٨، بينما تتراوح متوسط شدة انعكاسية بيانات ليدار لعينات أسطح الصبة ذات الأسمنت العادي بين ٩٨ و١٠٢ (مباني) و٥٨ و٧٠ (مواقف).

بناءً على تحليل متوسط شدة انعكاسية بيانات ليدار لعينات التصنيف، تم إنشاء خريطة موضوعية لأنواع الأسطح في منطقة الدراسة، الشكل (٣٠). تُظهر هذه الخريطة توزيع أنواع الأسطح المختلفة في المنطقة، مع تلوين كل نوع بلون محدد.

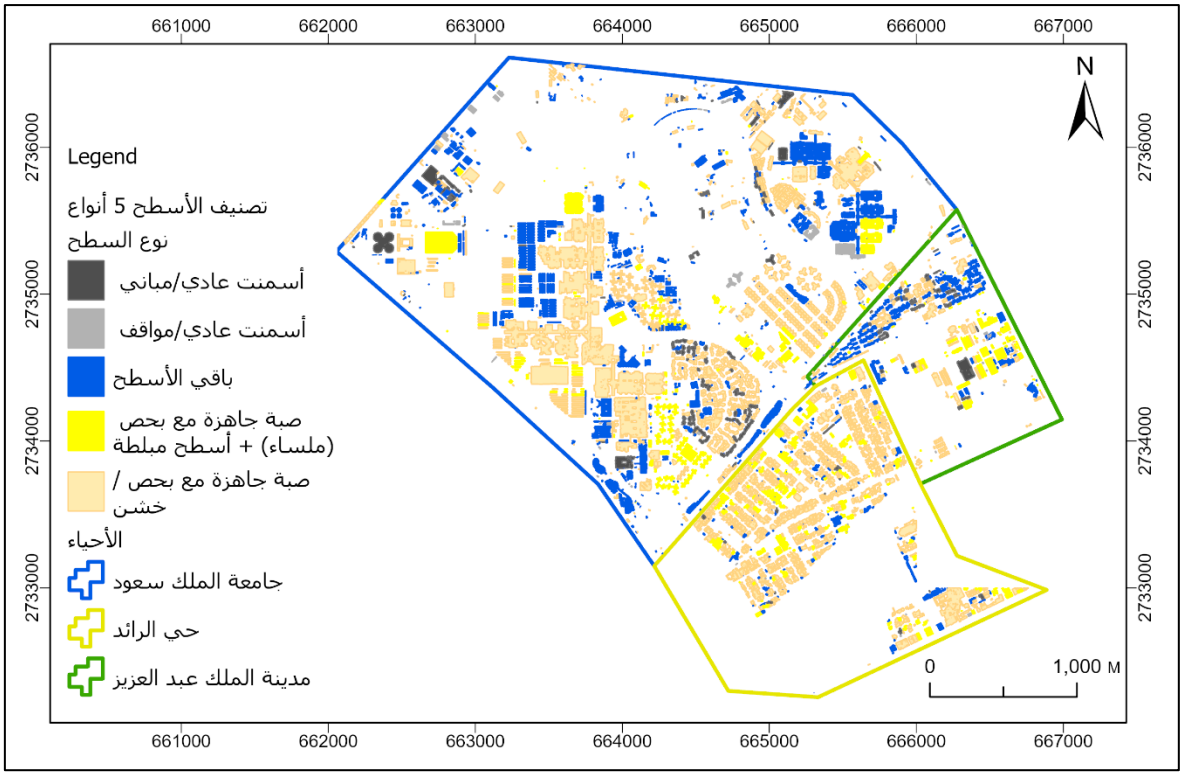

الشكل (٣٠) أنواع الأسطح في منطقة الدراسة حسب قيم شدة بيانات الليدار في بيئة GIS

٨.١.١٠. تقييم دقة استخلاص أسطح المباني وانواعها في بيئة GIS من بيانات الليدار:

- **الفحص البصري:**

تمت بداية عملية المقارنة البصرية بين الطبقة الناتجة عن بصمات المباني وكل من المرئية الفضائية عالية الدقة وخريطة الأساس (World Topographic Map) المتاحة في برنامج ArcGIS Pro.

لاحظنا وجود تطابق كبير بين البيانات المستخدمة في الطبقة وتلك الموجودة في المرئية الفضائية وأيضا تلك المتاحة في خريطة الأساس، الشكل (٣١).

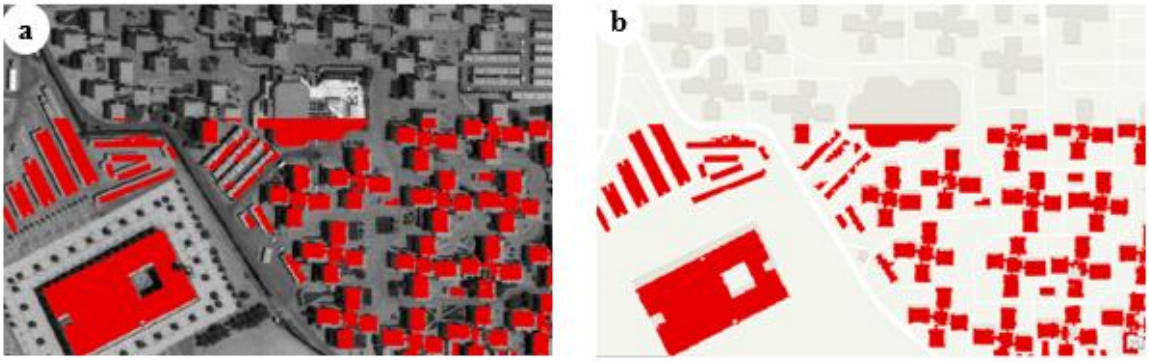

الشكل (٣١) مقارنة بصرية بين طبقة بصمات المباني الناتجة مع تلك الموجودة في المرئية الفضائية (a) وفي خريطة الأساس العالمية (b)

• تقييم دقة تجزئة غمامة الليدار:

لأغراض تقييم دقة تجزئة سحابة الليدار في هذه الدراسة، تم اختيار ٣٠ مبنى بشكل عشوائي داخل منطقة الدراسة الشكل (٣٢). تم استخدام المعادلة الموضحة في القسم النظري لحساب الدقة (تحسب نسبة الدقة كنسبة مئوية بقسمة عدد النقاط المجزئة بالطريقة المتبعة على عدد النقاط المجزئة يدويا). ويعرض الجدول (٢) نتائج تقييم الدقة.

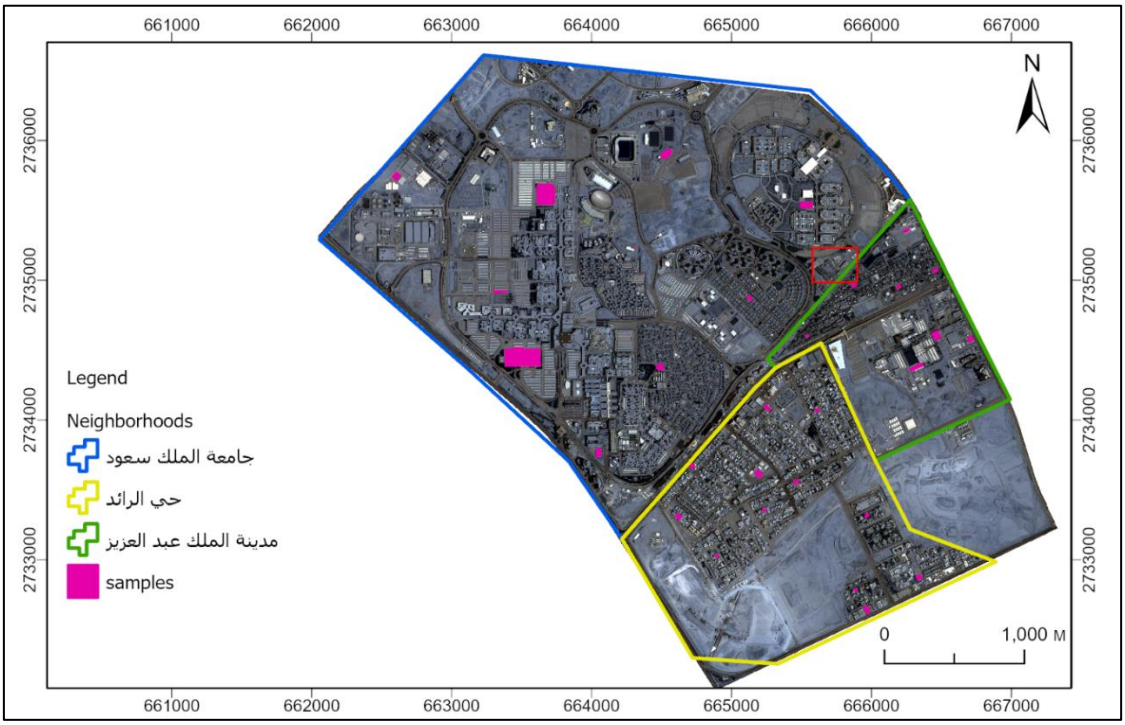

شكل (٣٢) عينات مباني الاختبار لتقييم دقة تجزئة غمامة الليدار

الجدول (٢) نتائج تقييم دقة تجزئة غمامة الليدار

رقم البناء	عدد النقاط المجزئة		Accuracy (%)	Average Accuracy (%)	الحي
	الطريقة المتبعة	يدويا			
١	٥٥	٦١	٩٠,٢	٨٥,٤	الرائد
٢	١١٥٦	١٣٩٣	٨٣		
٣	٢٧٣	٣٦٢	٧٥,٤		
٤	٨٦٧	١٠٥٨	٨١,٩		
٥	٥٥٥	٥٨٥	٩٤,٩		
٦	٧٣٣	٨١٣	٩٠,٢		
٧	٢٧٩	٣٦٢	٧٧,١		
٨	٣٥٦	٣٩٤	٩٠,٤		
٩	٩٢٩	١١٢١	٨٢,٩		
١٠	٦٨٨	٨٢٩	٨٣		
١١	٣٩٧	٤٦٠	٨٦,٣		
١٢	١٤٩٠	١٦١٩	٩٢		
١٣	٦٠٠	٧٢٦	٨٢,٦		
١٤	٢٨٢٢	٣١٧٢	٨٩	٨٨,٧	جامعة الملك سعود
١٥	٣٠٥٦	٣٢٥٠	٩٤		
١٦	٥٢٠	٦٤١	٨١,١		
١٧	١٨٠٩	١٩٣٦	٩٣,٤		
١٨	١٠٠٠	١٣١٠	٧٦,٣		
١٩	٣٦٤٩٣	٣٧٧٤٨	٩٦,٧		
٢٠	١٦١٩	١٩٠٠	٨٥,٢		
٢١	١٧٠٥٣	١٩٩٩٥	٨٥,٣		
٢٢	٢٠٥٥	٢١٢١	٩٦,٩		
٢٣	٥٩٧	٦٣٤	٩٤,٢	٨٢,٢	مدينة الملك عبد العزيز
٢٤	٦٠٦	٨٢٦	٧٣,٤		
٢٥	٤٨٠	٦٠١	٧٩,٩		
٢٦	٤٣٢	٦٣١	٦٨,٥		
٢٧	١٤٦	٢٥٥	٥٧,٣		
٢٨	١٩٦٠	٢٢٠٨	٨٨,٨		
٢٩	٢٧٤٧	٢٨٢٨	٩٧,١		
٣٠	١١١١	١١٢٣	٩٨,٩		
		Total	٨٥,٥		

من خلال الجدول (٢)، يمكن استخلاص النقاط التالية:

- هناك تباين في دقة تجزئة المباني الثلاثين، حيث تتراوح بين ٥٧,٣٪ و٩٨,٩٪.
- المبنى رقم ٣٠ (مدينة الملك عيد العزيز) يتمتع بأعلى دقة بنسبة ٩٨,٩٪، يليه المبنى رقم ٢٩ بنسبة ٩٧,١٪. في المقابل، يظهر المبنى رقم ٢٧ (مدينة الملك عيد العزيز) بأقل دقة بنسبة ٥٧,٣٪.
- متوسط الدقة الإجمالي لجميع المباني الثلاثين يبلغ ٨٥.٥٪. يُعتبر هذا المؤشر مقياسا شاملاً لدقة تجزئة سحابة الليدار داخل منطقة الدراسة بأكملها.
- المجموعتين المتضمنتين لحي جامعة الملك سعود وحي الرائد تتمتعان بدقة مرضية بشكل عام، حيث بلغ متوسط الدقة ٨٨,٧٪ و٨٥,٤٪ على التوالي. وفي حين أن هذه النتائج تعتبر مقبولة في مدينة الملك عيد العزيز (٨٢,٢٪)، إلا أنه يمكن ملاحظة أن حي جامعة الملك سعود يظهر بدقة أعلى مقارنة بحي الرائد.

يمكن أن يُعزى هذا الفارق في الدقة إلى عدة عوامل محتملة، مثل كثافة البيانات الملتقطة. كما أن تأثير ظروف الإضاءة يلعب دورا هاما في تحديد دقة تجزئة الليدار، حيث يمكن أن تسبب اختلافات في الإضاءة، سواء كانت ناتجة عن الظروف الجوية أو الوقت من اليوم، تغيرات في تباين الصور، مما يؤثر على قدرة الليدار على استنتاج المباني بدقة وتوليد نقاط شاذة. وقد يكون للبيئة المحيطة بالمباني تأثير أيضا، حيث تُعد تعقيدات البيئة المحيطة بالمباني من العوامل المؤثرة أيضا. وجود عوائق مثل الأشجار أو مباني أخرى يمكن أن يشكل تحديات إضافية في عملية تجزئة الليدار. تظهر هذه النتائج أهمية دراسة وتحليل عوامل التأثير على دقة تجزئة الليدار في كل حي بشكل فردي لتحسين النتائج وتحديد المجالات التي قد تحتاج إلى تحسين إضافي. أيضا، يعود الفارق في هياكل المباني نفسها إلى تحديات إضافية في تجزئة الليدار. فاختلاف في الأشكال والأحجام قد يتطلب تقنيات تجزئة مختلفة، والتي قد تكون أكثر أو أقل فعالية اعتمادًا على الخصائص الفريدة لكل هيكل.

• تقييم دقة استخلاص أسطح المباني من غمامة الليدار:

من حيث الطوبولوجيا تم المقارنة بين البيانات المرجعية والنتائج المصنفة، حيث يُظهر الشكل (٣٣) عينات من المناطق التي تعبر عن البيانات المرجعية ونتائج التصنيف، حيث توجد بعض الاختلافات في الطوبولوجيا والتوجيه بين البيانات المرجعية ونتائج التصنيف.

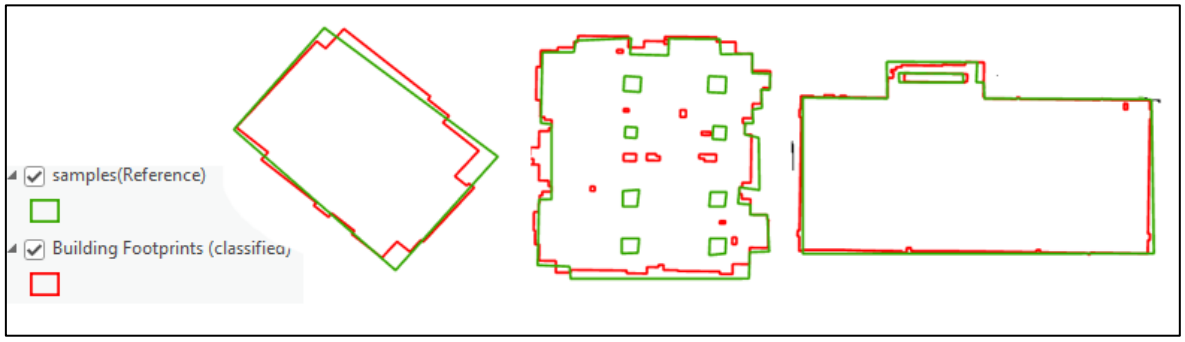

الشكل (٣٣) اختلاف في الطوبولوجيا بين البيانات المرجعية والنتيجة المصنفة

لتقييم دقة استخلاص أسطح المباني من غمامة الليدار باستخدام طريقة التداخل المتبادل كتابع للمساحة، تم إجراء عملية تراكب باستخدام طريقة التقاطع لتحديد منطقة التداخل المتبادل باستخدام العتبة ٦٠٪. حيث يتم حساب نسبة التداخل المتبادل للاكتمال على النحو التالي:

$$comp. = \frac{\text{Cumulative Area of Mutual Overlap Area}}{\text{Cumulative Area of Reference Buildings}} * 100$$

ويتم حساب نسبة التداخل المتبادل للصحة على النحو التالي:

$$\text{Corre.} = \frac{\text{Cumulative Area of Mutual Overlap Area}}{\text{Cumulative Area of Classified Buildings}} * 100$$

باستخدام أدوات المعالجة الجغرافية ضمن ArcGIS Pro، تم حساب منطقة التداخل والنسب المئوية، ويظهر الجدول (٣) نتائج تحليل الدقة.

الجدول (٣) نتائج تحليل دقة استخلاص أسطح المباني من غمامة الليدار

طريقة التداخل المتبادل (العتبة المستخدمة ٦٠٪)	
المعيار	القيمة %
Completeness الاكتمال	٩٣,٤
Correctness الصحة	٩٣,٧
Quality الجودة	٨٨

تشير نتائج الدقة الموضحة في الجدول (٣) إلى أن جودة البيانات (الدقة الإجمالية) بلغت ٨٨٪.كما توضح مقاييس الدقة أن عملية استخراج أسطح المباني من بيانات الليدار ذات دقة عالية، حيث بلغت نسبة الاكتمال ٩٣,٤، وبلغت نسبة الصحة ٩٣,٧٪. يمكن تحسين هذه الدقة باستخدام بيانات ليدار ذات كثافة أعلى من المستخدمة حاليا، مما سيؤدي إلى زيادة نسبة الاكتمال وصحة النتائج.

• تقييم دقة تصنيف أنواع الأسطح في بيئة GIS:

من أجل تقييم دقة تصنيف أنواع الأسطح في بيئة GIS. تم استخدام عينات الاختبار والبالغ عددها ٦٠ عينة، حيث تم بداية استخلاص قيم التصنيف من طبقة أنواع الأسطح المصنفة، ثم تم حساب مصفوفة الخطأ والتي تم توضيح نتائجها في الجدول (٤).

الجدول (٤) مصفوفة الخطأ لتقييم تصنيف أنواع أسطح المباني باستخدام بيانات شدة LiDAR وأدوات GIS

ClassValue	C_1	C_2	C_3	C_4	C_5	C_6	Total	U_Accuracy	Kappa
C_1	13	0	4	0	0	2	19	0.68	0
C_2	15	2	3	0	1	10	31	0.06	0
C_3	0	0	0	0	0	0	0	0	0
C_4	0	1	0	0	0	0	1	0	0
C_5	0	0	0	0	0	0	0	0	0
C_6	0	2	1	2	0	4	9	0.44	0
Total	28	5	8	2	1	16	60	0	0
P_Accuracy	0.46	0.4	0	0	0	0.25	0	**0.32**	0
Kappa	0	0	0	0	0	0	0	0	**0.11**

C_1	صبة_جاهزة_بحص/ملساء	**C_3**	بلاط_مبنى	**C_5**	اسمنت_عادي_مواقف
C_2	صبة_جاهزة_بحص/خشنة	**C_4**	اسمنت_عادي_مبنى	**C_6**	باقي_الاسطح

بناءً على مصفوفة الخطأ الموضحة في الجدول (٤)، يمكن استخلاص المعلومات التالية حول أداء نموذج تصنيف أنواع أسطح المباني باستخدام بيانات شدة LiDAR:

- بلغت الدقة العامة ٠,٣٢، مما يعني أن النموذج حقق دقة كلية تبلغ ٣٢٪ على بيانات الاختبار، أي صنف ١٩ عينة فقط بشكل صحيح من بين ٦٠ عينة.
- أظهر النموذج أداء متوسطا بالنسبة للصنف C_1 (صبة_جاهزة_بحص/ملساء)، حيث صنف ١٣ عينة بشكل صحيح من بين ٢٨ بدقة مستخدم U_Accuracy بلغت ٦٨٪ ودقة منتج P_Accuracy بلغت ٤٦٪. وتم تصنيف أكثر من نصف عينات هذا الصنف على أنها من الصنف C_2 (صبة_جاهزة_بحص/خشنة).
- تم تصنيف معظم العينات في الأصناف C_2، C_3، C_4، C_5 بشكل خاطئ.
- بالنسبة للصنف C_6 (باقي الأسطح)، كان أداءه ضعيفا، حيث تم تصنيف ٤ عينات فقط بشكل صحيح من بين ١٦، وبدقة مستخدم U_Accuracy بلغت ٤٤٪ ودقة منتج P_Accuracy بلغت ٢٥٪.
- تشير إحصائية كابا (Kappa) بقيمتها ٠,١١ إلى وجود مستوى ضعيف من التطابق بين تنبؤات النموذج والتصنيفات الفعلية، وأنه ليس مثالياً.

٨.٢. نتائج التصنيف الهدفي لاستخلاص أسطح المباني ونوعيتها من بيانات الليدار:

٨.٢.١. التصنيف الهدفي لاستخلاص أسطح المباني من بيانات الليدار:

يوضح الشكل (٣٤) طبقة أسطح المباني في منطقة الدراسة، والتي تم استخلاصها من التصنيف الهدفي لبيانات الليدار فقط.

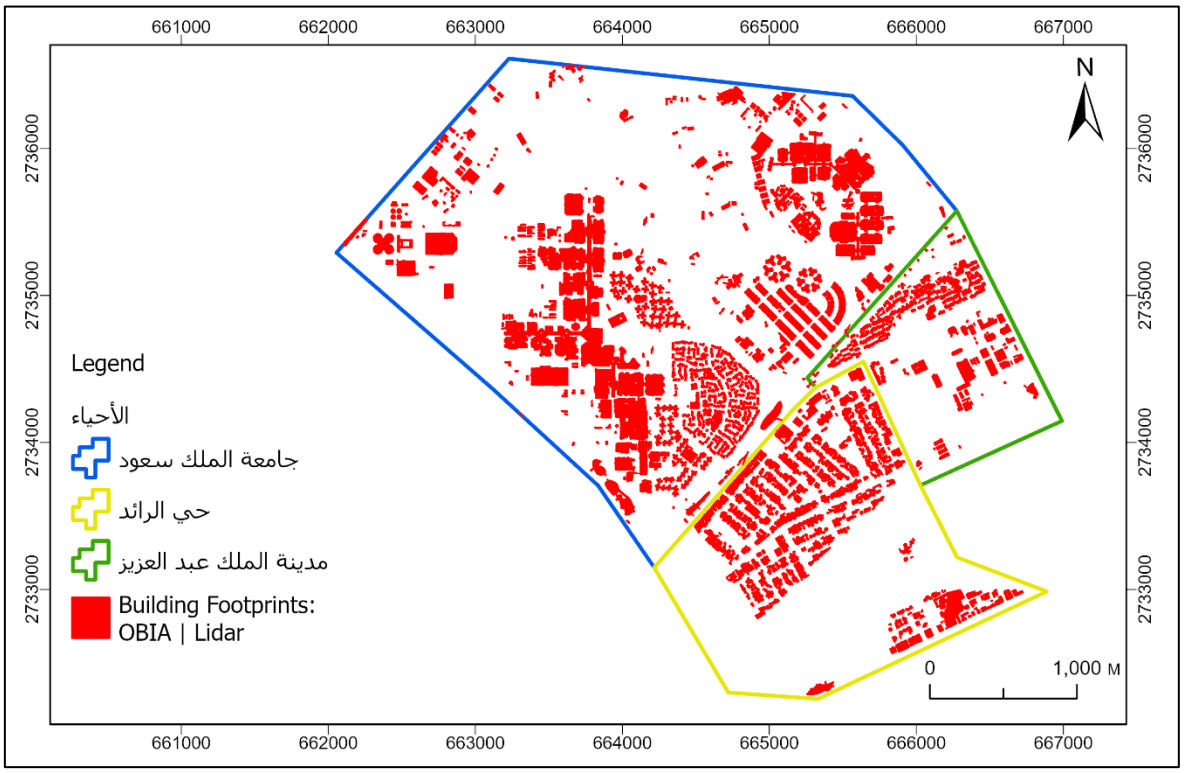

الشكل (٣٤) طبقة أسطح المباني التي تم استخلاصها من التصنيف الهدفي لبيانات الليدار

وفيما يلي بعض الإحصائيات عن أسطح المباني المستخلصة من التصنيف الهدفي لبيانات الليدار، كما هو موضح في الجدول (٥).

الجدول (٥) إحصائيات طبقة أسطح المباني التي تم استخلاصها من التصنيف الهدفي لبيانات الليدار

	حي جامعة الملك سعود	حي الرائد	مدينة الملك عبد العزيز	المجموع
عدد الأسطح المستخلصة	١١٣٤	٨٦١	٤٥٢	٢٢٤٩
مساحة الأسطح م^2	١٣٤٢٢٣٨,٩	٤٠٥٢٧٠,٩	١٦٧٢٧٠,٤	١٩١٤٤٧٨,٨

نلاحظ من خلال الجدول (٥) أن عدد الأسطح الكلي المستخرج في منطقة الدراسة من بيانات الليدار باستخدام التصنيف الهدفي هو ألفان ومائتان وتسع وأربعون (٢٢٤٩) سطحا، وبلغت مساحتها الكلية حوالي مليون وتسعمائة وأربعة عشر ألفا وأربعمائة وثمانية وسبعون (١,٩١٤,٤٧٨) مترا مربعا.

٨.٢.٢. التصنيف الهدفي لاستخلاص أنواع أسطح المباني من بيانات الليدار:

توضح الخرائط الموضوعية التالية، الشكل (٣٥), الشكل (٣٦) والشكل (٣٧)، نتائج التصنيف الهدفي لأنواع الأسطح من بيانات LiDAR فقط باستخدام ثلاث خوارزميات مختلفة: آلة دعم المتجهات (SVM) وشجرة القرار (DT) والغابة العشوائية (RT).

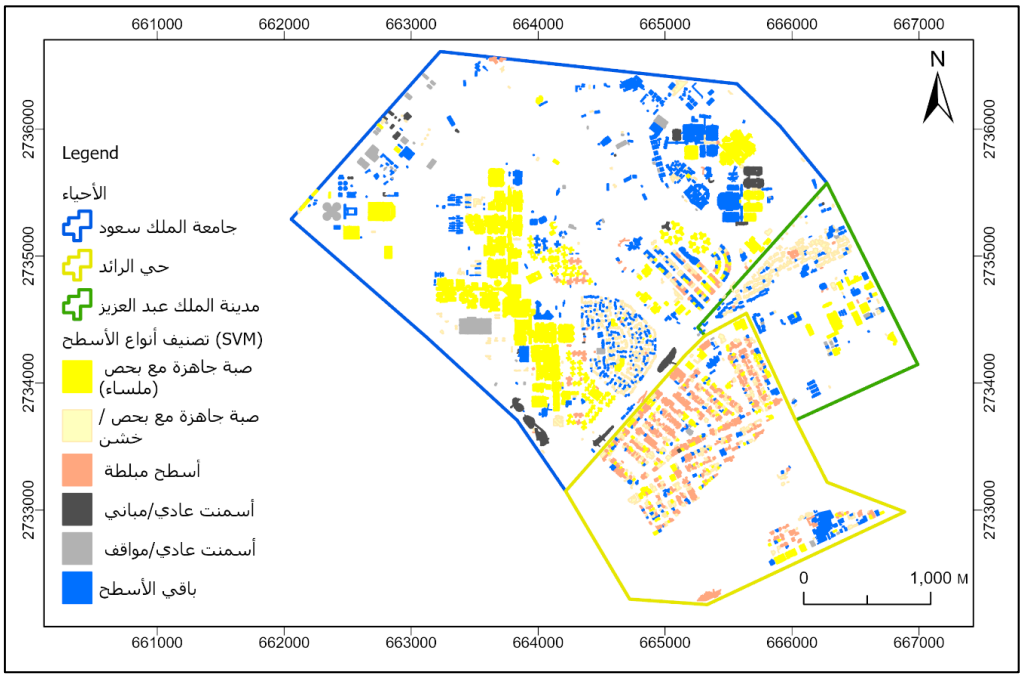

الشكل (٣٥) التصنيف الهدفي لأنواع الاسطح من بيانات الليدار باستخدام خوارزمية SVM

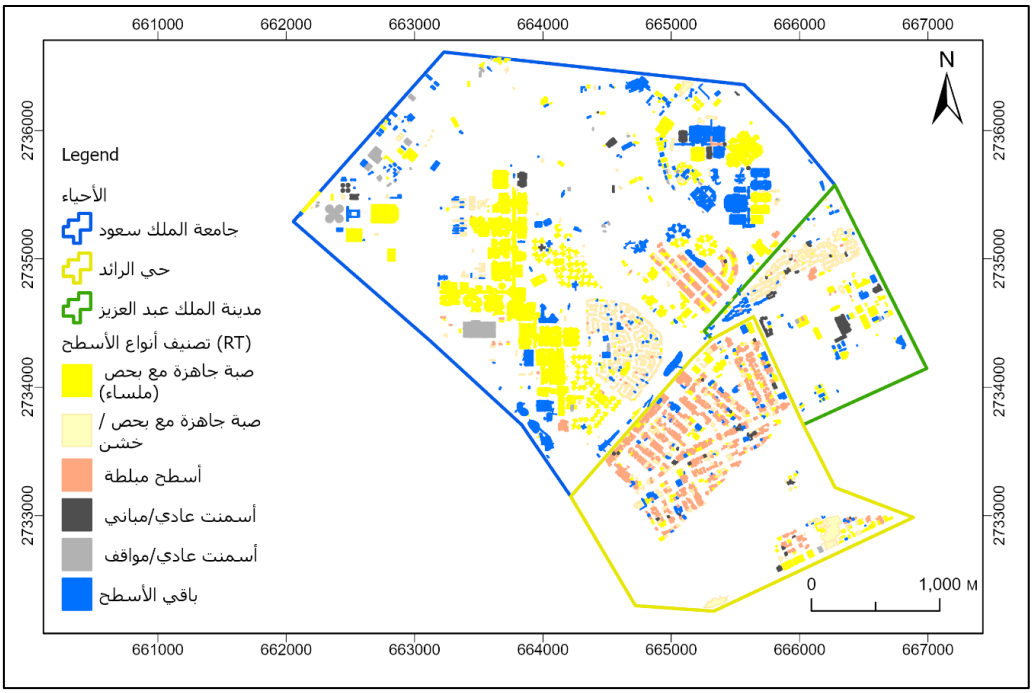

الشكل (٣٦) التصنيف الهدفي لأنواع الاسطح من بيانات الليدار باستخدام خوارزمية RT

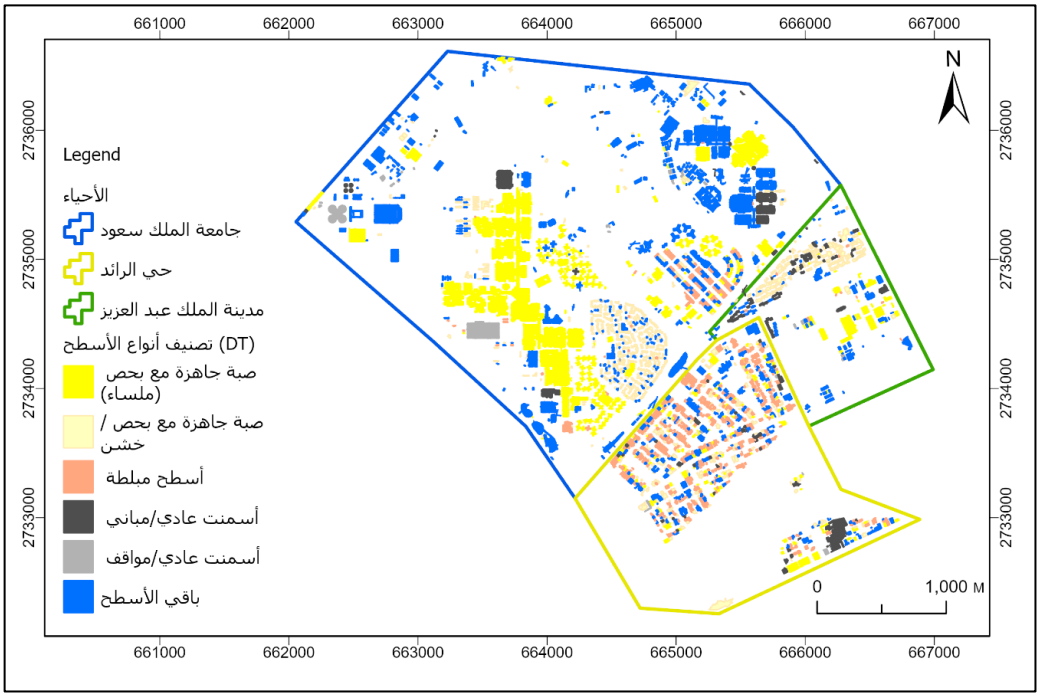

الشكل (٣٧) التصنيف الهدفي لأنواع الاسطح من بيانات الليدار باستخدام خوارزمية DT

٨.٢.٣. تقييم دقة نتائج التصنيف الهدفي لاستخلاص أسطح المباني ونوعيتها من بيانات الليدار:

• تقييم نتائج استخلاص فئة أسطح المباني من بيانات الليدار:

تم إجراء تحليل بصري لنتائج التصنيف الهدفي لبيانات الليدار، حيث تمّت المقارنة بين البيانات المرجعية (٣٠ مبنى عشوائي) ونتائج التصنيف، الشكل (٣٨). أظهرت المقارنة وجود بعض الاختلافات في الطوبولوجيا والتوجيه بين البيانات المرجعية ونتائج التصنيف، حيث تمّ رصد فقدان بعض التفاصيل داخل الحيز المكاني للمبنى. ووجود تعرجات كثيرة داخل أو خارج خطوط البيانات المرجعية.

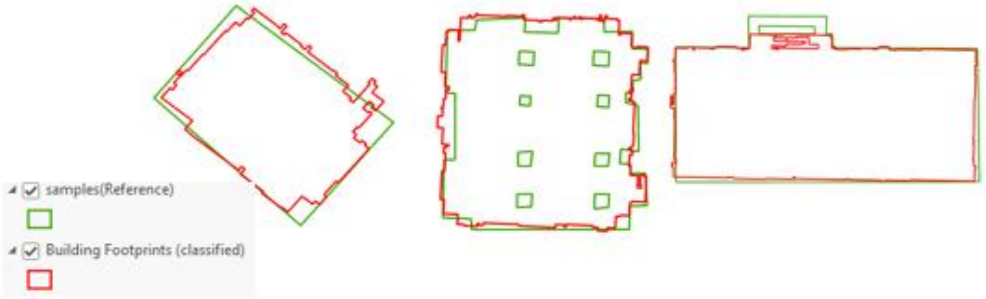

الشكل (٣٨) اختلاف في الطوبولوجيا بين البيانات المرجعية والنتيجة المصنفة هدفيا

بمقارنة نتائج استخراج أسطح المباني باستخدام خوارزمية التصنيف الهدفي مع نتائج استخراجها باستخدام أدوات GIS، كما هو موضح في الشكل (٣٣)، نجد أن أدوات GIS تعطي نتائج أفضل من حيث الطوبولوجيا.

لتقييم دقة التصنيف الهدفي لاستخلاص أسطح المباني من بيانات الليدار باستخدام طريقة التداخل المتبادل كتابع للمساحة، تم إجراء عملية تراكب باستخدام طريقة التقاطع لتحديد منطقة التداخل المتبادل باستخدام العتبة ٦٠٪. باستخدام أدوات المعالجة الجغرافية ضمن ArcGIS Pro، تم حساب منطقة التداخل والنسب المئوية، ويظهر الجدول (٦) نتائج تحليل الدقة.

الجدول (٦) نتائج تحليل دقة التصنيف الهدفي لاستخلاص أسطح المباني من بيانات الليدار

طريقة التداخل المتبادل (العتبة المستخدمة ٦٠٪)	
المعيار	القيمة %
الاكتمال Completeness	٩٠,٩٩
الصحة Correctness	٩٢,١٥
الجودة Quality	٨٤,٤

تشير نتائج الدقة الموضحة في الجدول (٦) إلى أن جودة البيانات (الدقة الإجمالية) بلغت ٨٤,٤٪، كما توضح مقاييس الدقة أن عملية استخراج أسطح المباني ذات دقة جيدة جدا، حيث بلغت نسبة الاكتمال ٩٠,٩٩، وبلغت نسبة الصحة ٩٢,١٥٪ .

بناءً على مقارنة هذه النتائج مع النتائج التي تم الحصول عليها في نتيجة استخراج أسطح المباني من بيانات الليدار في بيئة نظم المعلومات الجغرافية GIS، الجدول (٣)، تم رسم المخطط الموضح في الشكل (٣٩).

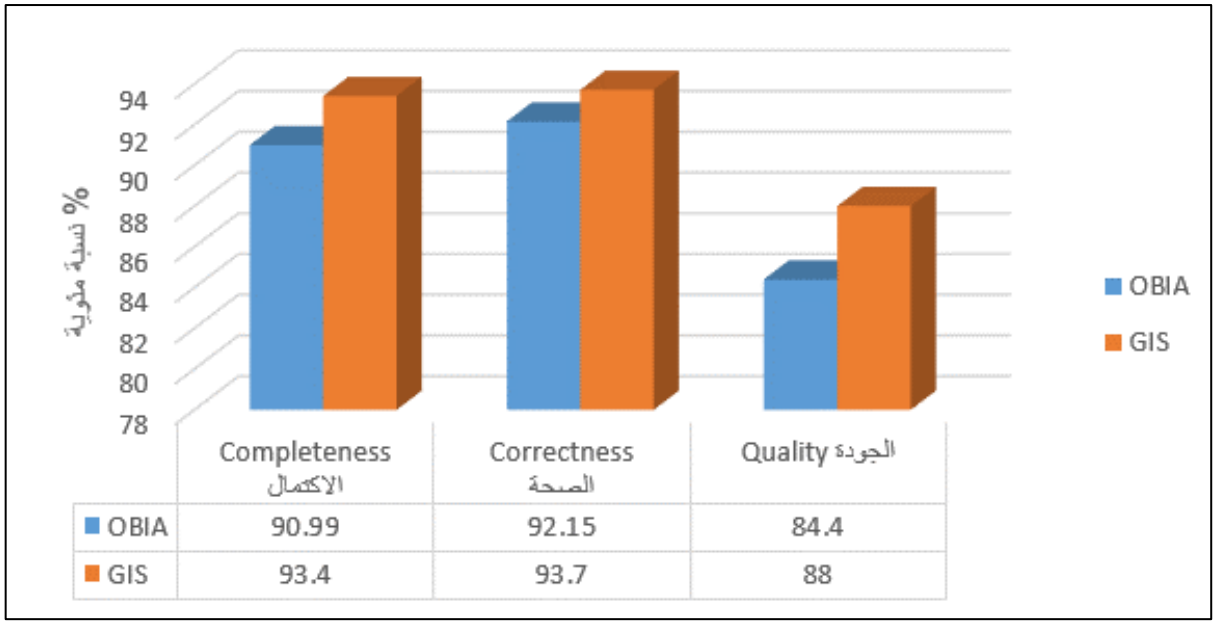

الشكل (٣٩) مقارنة دقة استخراج أسطح المباني من بيانات الليدار في بيئة GIS والتصنيف الهدفي

يتضح من الشكل (٣٩) أن النتائج متقاربة بشكل عام، مع تفوق استخراج أسطح المباني من بيانات الليدار في بيئة GIS بنسبة ٨٨٪ على التصنيف الهدفي لاستخراج أسطح المباني من بيانات الليدار، حيث بلغت دقة الأولى ٨٨٪ مقابل ٨٤,٤٪ للثانية. يعود هذا التفوق إلى الدقة المكانية العالية لإحداثيات نقاط بيانات الليدار، حيث تعتمد طريقة استخراج أسطح المباني في بيئة GIS بشكل اساسي على دقة وكثافة إحداثيات نقاط الليدار. ومع ذلك، قد يؤدي تحويل هذه النقاط إلى طبقات راستر (مثل السطوح التي تمثل الارتفاع، أو الانحدار، أو اتجاه السطح، أو قيم شدة الانعكاس) وتصنيفها هدفياً إلى انخفاض جودة النتائج. علاوة على ذلك، تلعب عوامل أخرى دورا في التأثير على النتائج، مثل: عدد طبقات التقسيم في عملية التجزئة. نوع التجزئة المستخدمة. معاملات المقياس، الشكل، الاكتناز، وغيرها من المعاملات. ومن المتوقع أن يؤدي دمج بيانات الليدار مع صور فضائية عالية الدقة إلى تحسين جودة النتائج بشكل ملحوظ.

- **تقييم دقة نتائج استخلاص انواع أسطح المباني من بيانات الليدار:**

من أجل تقييم تصنيف أنواع أسطح المباني باستخدام بيانات شدة LiDAR واستخدام ثلاث خوارزميات مختلفة: آلة دعم المتجهات (SVM) والغابة العشوائية (RT). وشجرة القرار (DT)، تم حساب مصفوفات الخطأ باستخدام عينات الاختبار (٦٠عينة)، ونتائج هذه المصفوفات موضحة في الجدول (٧)، الجدول (٨) والجدول (٩).

الجدول (٧) مصفوفة الخطأ لتقييم تصنيف أنواع أسطح المباني باستخدام بيانات شدة LiDAR وخوارزمية SVM

ClassValue	C_1	C_2	C_3	C_4	C_5	C_6	Total	U_Accuracy	Kappa
C_1	24	0	0	0	1	7	32	0.75	0
C_2	0	3	2	0	0	1	6	0.5	0
C_3	3	0	5	0	0	2	10	0.5	0
C_4	0	0	0	0	0	0	0	0	0
C_5	0	0	0	0	0	1	1	0	0
C_6	1	2	1	2	0	5	11	0.45	0
Total	28	5	8	2	1	16	60	0	0
P_Accuracy	0.86	0.6	0.63	0	0	0.31	0	0.62	0
Kappa	0	0	0	0	0	0	0	0	0.43
C_1	صبة_جاهزة_بحص/ملساء		C_3	بلاط_مبنى		C_5	اسمنت_عادي_مواقف		
C_2	صبة_جاهزة_بحص/خشنة		C_4	اسمنت_عادي_مبنى		C_6	باقي_الاسطح		

الجدول (٨) مصفوفة الخطأ لتقييم تصنيف أنواع أسطح المباني باستخدام بيانات شدة LiDAR وخوارزمية RT

ClassValue	C_1	C_2	C_3	C_4	C_5	C_6	Total	U_Accuracy	Kappa
C_1	27	0	0	0	1	8	36	0.75	0
C_2	0	3	1	1	0	2	7	0.43	0
C_3	1	0	5	0	0	1	7	0.71	0
C_4	0	1	1	0	0	0	2	0	0
C_5	0	0	0	0	0	0	0	0	0
C_6	0	1	1	1	0	5	8	0.63	0
Total	28	5	8	2	1	16	60	0	0
P_Accuracy	0.96	0.6	0.63	0	0	0.32	0	0.67	0
Kappa	0	0	0	0	0	0	0	0	0.49

C_1	صبة_جاهزة_بحص/ملساء	C_3	بلاط_مبنى	C_5	اسمنت_عادي_مواقف
C_2	صبة_جاهزة_بحص/خشنة	C_4	اسمنت_عادي_مبنى	C_6	باقي_الاسطح

الجدول (٩) مصفوفة الخطأ لتقييم تصنيف أنواع أسطح المباني باستخدام بيانات شدة LiDAR وخوارزمية DT

ClassValue	C_1	C_2	C_3	C_4	C_5	C_6	Total	U_Accuracy	Kappa
C_1	24	0	0	0	1	6	31	0.77	0
C_2	0	3	1	0	0	2	6	0.5	0
C_3	1	0	4	0	0	1	6	0.67	0
C_4	1	1	1	1	0	0	4	0.25	0
C_5	0	0	0	0	0	0	0	0	0
C_6	2	1	2	1	0	7	13	0.54	0
Total	28	5	8	2	1	16	60	0	0
P_Accuracy	0.86	0.6	0.5	0.5	0	0.44	0	0.65	0
Kappa	0	0	0	0	0	0	0	0	0.48

C_1	صبة_جاهزة_بحص/ملساء	C_3	بلاط_مبنى	C_5	اسمنت_عادي_مواقف
C_2	صبة_جاهزة_بحص/خشنة	C_4	اسمنت_عادي_مبنى	C_6	باقي_الاسطح

تشير نتائج الدقة الموضحة في الجداول السابقة أن الخوارزميات الثلاثة أظهرت أداءً متقاربا، مع حصول خوارزمية RT على أعلى دقة إجمالية (٠,٦٧) ومعامل Kappa (٠,٤٩). بينما سجلت خوارزمية SVM وDT دقة إجمالية تبلغ ٠,٦٢ و٠,٦٥ ومعامل Kappa 0.43 و٠,٤٨ على التوالي. حيث تختلف دقة التصنيف اعتمادا على جودة بيانات LiDAR ونوعيات اسطح المباني المحددة.

بمقارنة نتائج هذه الخوارزميات مع النتيجة التي حصلنا عليها باستخدام أدوات GIS، الشكل (٤٠)، يتضح أن أدوات GIS أظهرت دقة إجمالية أقل بكثير من الخوارزميات الثلاثة، حيث بلغت ٠,٣٢ ومعامل Kappa 0.11.

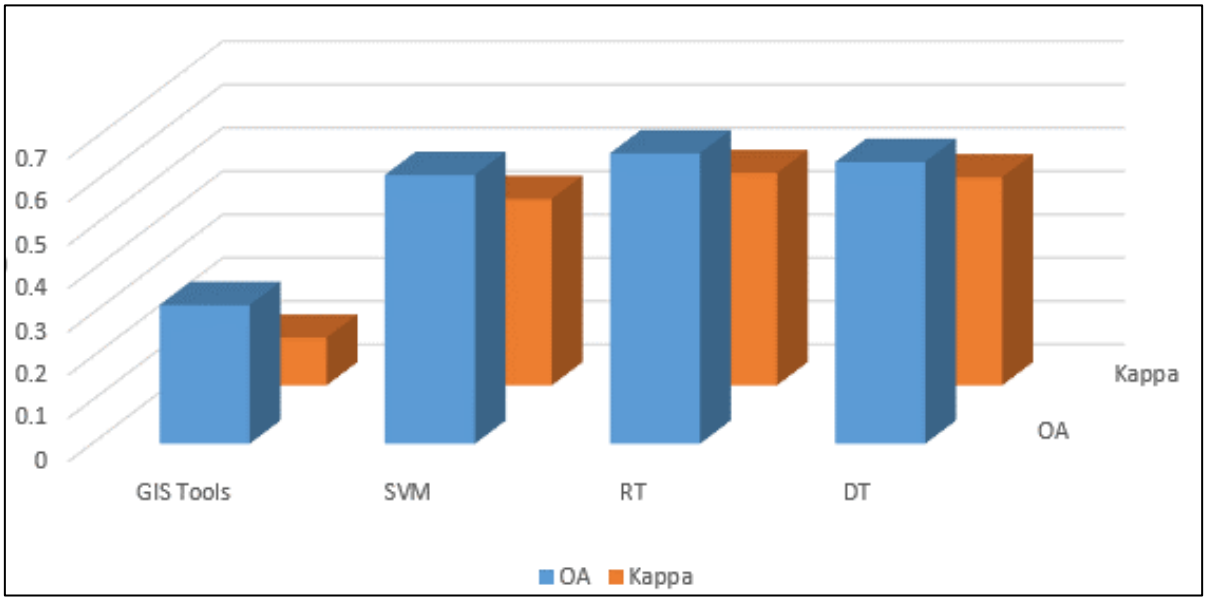

الشكل (٤٠) مقارنة نتائج خوارزميات SVM RT وDT والتصنيف باستخدام أدوات GIS. لتصنيف أنواع الاسطح من بيانات الليدار

يمكن تفسير ذلك بعدة عوامل، من أهمها:

- استخدام التصنيف اليدوي: حيث تعتمد أدوات GIS بشكل أساسي على التصنيف اليدوي لبيانات قيم شدة LiDAR، مما قد يؤدي إلى حدوث أخطاء بشرية وتباين في الدقة.
- مجالات غير دقيقة لبيانات شدة الليدار: قد لا تكون مجالات بيانات قيم شدة الليدار المستخدمة في أدوات GIS دقيقة بما يكفي لتمييز أنواع الأسطح المختلفة بشكل صحيح.
- تداخل بيانات قيم شدة الليدار بين بعض أنواع الأسطح.

توفر خوارزميات SVM وDT وRT أدوات فعالة لتصنيف أنواع الأسطح من بيانات LiDAR، ومع أنها أظهرت تفوقا كبيرا على أدوات GIS. غير انها بحاجة تحسين النتائج وذلك من خلال دمج مصادر بيانات أخرى مع بيانات الليدار، لتحسين دقة التصنيف للخوارزميات الثلاثة. وتقييم أداء الخوارزميات بشكل أكثر شمولاً باستخدام مجموعة بيانات اختبار أكبر.

تُظهر نتائج هذه الدراسة أن تحليل متوسط شدة انعكاسية بيانات ليدار يمكن أن يكون نهجا فعالا لتصنيف أنواع مختلفة من أسطح المباني. ومع ذلك، هناك حاجة إلى مزيد من البحث لتحسين دقة التصنيف، خاصة في الحالات التي يكون فيها تداخل بين شدة انعكاسية بيانات ليدار لبعض أنواع الأسطح.

يمكن التغلب على قيود تصنيف أسطح المباني باستخدام بيانات ليدار باستخدام بيانات إضافية مثل المرئيات الفضائية عالية الدقة ذات النطاقات المرئية (VNIR) والحرارية (SWIR) حيث يمكن استخدام هذه البيانات لتمييز خصائص سطح المبنى، مثل الشكل والحجم والمواد. وكذلك تقنيات تصنيف أكثر تقدما مثل التصنيف الهدفي حيث يمكن استخدام هذه التقنية لتصنيف أسطح المباني بناءً على خصائص محددة، مثل قيم SWIR وشدة انعكاسية بيانات ليدار ونسيج السطح والسياق المكاني. من خلال دمج هذه البيانات والتقنيات، يمكن تحسين دقة تصنيف أسطح المباني بشكل كبير.

٩. الاستنتاجات والتوصيات:

توصلت هذه الدراسة إلى أن كلا من معالجة بيانات LiDAR في بيئة نظم المعلومات الجغرافية (GIS) والتصنيف الهدفي يعتبران نهجين فعالين لاستخلاص أسطح المباني في المناطق الحضرية، مع تفوق طفيف لأدوات GIS في دقة استخراج أسطح المباني (٨٨٪) مقارنة بالتصنيف الهدفي (٨٤,٤٪). يرجع ذلك إلى الاعتماد المباشر لأدوات GIS على دقة بيانات LiDAR المكانية.

على الرغم من تفوق أدوات GIS في استخراج أسطح المباني، إلا أن خوارزميات التصنيف الهدفي أظهرت أداءً أفضل في تصنيف أنواع الأسطح. حققت خوارزمية RT أعلى دقة إجمالية (٦٧٪) ومقياس Kappa (٠,٤٩) مقارنة بأدوات GIS التي سجلت دقة إجمالية ٣٢٪ ومقياس Kappa 0.11. يُعزى ذلك إلى القيود في التصنيف اليدوي وتداخل قيم شدة LiDAR بين بعض أنواع الأسطح، مما يؤكد على ضرورة تطوير تقنيات تصنيف أكثر تقدماً.

تشير نتائج هذه الدراسة إلى أن دمج بيانات LiDAR مع صور فضائية عالية الدقة (VNIR وSWIR) يُعتبر نهجا مفيدا لتحسين دقة تصنيف أنواع الأسطح والتغلب على القيود الموجودة في كلا النهجين. بالإضافة إلى ذلك، يوصى بإجراء المزيد من الأبحاث لتقييم أداء خوارزميات تصنيف مختلفة، مثل الشبكات العصبية العميقة، ودراسة تأثير عوامل أخرى على دقة التصنيف، مثل خصائص المباني والبيئة المحيطة. حيث يمكن ذلك من تحسين دقة استخلاص أسطح المباني وتصنيف أنواعها من بيانات LiDAR، مما يُسهم في تطوير تطبيقات متنوعة في مجالات التخطيط الحضري، إدارة الكوارث، تقييم الأثر البيئي، وغيرها من المجالات ذات الصلة.

١٠. المراجع:

١٠.١. المراجع العربية:

- الأمم المتحدة – إدارة الشؤون الاقتصادية والاجتماعية (٢٠١٤)، رصد السكان في العالم.

https://www.un.org/en/development/desa/population/publications/pdf/trends/Concise%20Report%20on%20the%20World%20Population%20Situation%202014/ar.pdf.

- الجعيدي, ف. ب. ح., & المثيبي, ع. ا. ب. م. (٢٠٢١)، تقييم أسلوب التصنيف الهدفي (OBC) لاستخراج المباني من المرئيات الفضائية Journal Architecture & Planning, 33(1).
- محسن, ع. ا., & الشرفاء, ع. (٢٠١٩)، السعة الإجمالية للطاقة الشمسية الكهروضوئية الموزعة التي يمكن تركيبها في الرياض: دراسة من خلال نظام المعلومات الجغرافية.

https://www.kapsarc.org/ar/research/publications/the-potential-of-distributed-solar-pv-capacity-in-riyadh-a-gis-assisted-study/.

١٠.٢. المراجع الأجنبية:

- *Adeleke, A. K. (2018). Web-based GIS modelling of building-integrated solar photovoltaic system for the City of Cape Town.*
- *Adeleke, A. K., & Smit, J. L. (2020). Building roof extraction as data for suitability analysis. Applied Geomatics, 12(4), 455–466.*
- *Attarzadeh, R., & Momeni, M. (2018). Object-Based Rule Sets and Its Transferability for Building Extraction from High Resolution Satellite Imagery. Journal of the Indian Society of Remote Sensing, 46(2). https://doi.org/10.1007/s12524-017-0694-6.*
- *Awrangjeb, M., & Lu, G. (2013). Building roof plane extraction from LIDAR data. 2013 International Conference on Digital Image Computing: Techniques and Applications, DICTA 2013. https://doi.org/10.1109/DICTA.2013.6691490.*
- *Chen, K., Lu, W., Xue, F., Tang, P., & Li, L. H. (2018). Automatic building information model reconstruction in high-density urban areas: Augmenting multi-source data with architectural knowledge. Automation in Construction, 93. https://doi.org/10.1016/j.autcon.2018.05.009.*
- *Congalton, R. G. (2001). Accuracy assessment and validation of remotely sensed and other spatial information. International Journal of Wildland Fire, 10(3–4). https://doi.org/10.1071/wf01031.*

- *Esch, T., Brzoska, E., Dech, S., Leutner, B., Palacios-Lopez, D., Metz-Marconcini, A., Marconcini, M., Roth, A., & Zeidler, J. (2022). World Settlement Footprint 3D - A first three-dimensional survey of the global building stock. Remote Sensing of Environment, 270. https://doi.org/10.1016/j.rse.2021.112877.*
- *Esri. (2024, January 3). ArcGIS Pro help—ArcGIS Pro | Documentation - Esri. Https://Pro.Arcgis.Com/En/pro-App/3.0/Help.*
- *Fareed, N., Flores, J. P., & Das, A. K. (2023). Analysis of UAS-LiDAR Ground Points Classification in Agricultural Fields Using Traditional Algorithms and PointCNN. Remote Sensing, 15(2). https://doi.org/10.3390/rs15020483.*
- *Foody, G. M. (2002). Status of land cover classification accuracy assessment. Remote Sensing of Environment, 80(1), 185–201. https://doi.org/10.1016/S0034-4257(01)00295-4.*
- *Foody, G. M. (2009). Sample size determination for image classification accuracy assessment and comparison. International Journal of Remote Sensing, 30(20), 5273–5291. https://doi.org/10.1080/01431160903130937.*
- *Gao, R., Park, J., Hu, X., Yang, S., & Cho, K. (2021). Reflective noise filtering of large-scale point cloud using multi-position lidar sensing data. Remote Sensing, 13(16). https://doi.org/10.3390/rs13163058.*
- *Gergelova, M. B., Labant, S., Kuzevic, S., Kuzevicova, Z., & Pavolova, H. (2020). Identification of roof surfaces from LiDAR cloud points by GIS tools: A case study of Lučenec, Slovakia. Sustainability (Switzerland), 12(17). https://doi.org/10.3390/SU12176847.*
- *Hoefle, B., Rutzinger, M., Geist, T., & Stï¿½tter, J. (2006). Using airborne laser scanning data in urban data management - set up of a flexible information system with open-source components. Proceedings UDMS 2006: Urban Data Management Symposium.*
- *Huang, H., Chen, P., Xu, X., Liu, C., Wang, J., Liu, C., Clinton, N., & Gong, P. (2022). Estimating building height in China from ALOS AW3D30. ISPRS Journal of Photogrammetry and Remote Sensing, 185. https://doi.org/10.1016/j.isprsjprs.2022.01.022.*
- *Jung, J., Jwa, Y., & Sohn, G. (2017). Implicit regularization for reconstructing 3D building rooftop models using airborne LiDAR data. Sensors (Switzerland), 17(3). https://doi.org/10.3390/s17030621.*
- *Kaartinen, E., Dunphy, K., & Sadhu, A. (2022). LiDAR-Based Structural Health Monitoring: Applications in Civil Infrastructure Systems. In Sensors (Vol. 22, Issue 12). https://doi.org/10.3390/s22124610.*
- *Kashani, A. G., Olsen, M. J., & Graettinger, A. J. (2015). Laser scanning intensity analysis for automated building wind damage detection. Congress on Computing*

in Civil Engineering, Proceedings, 2015-January (January). https://doi.org/10.1061/9780784479247.025.

- *Klápště, P., Fogl, M., Barták, V., Gdulová, K., Urban, R., & Moudrý, V. (2020). Sensitivity analysis of parameters and contrasting performance of ground filtering algorithms with UAV photogrammetry-based and LiDAR point clouds. International Journal of Digital Earth. https://doi.org/10.1080/17538947.2020.1791267.*
- *Kuras, A., Brell, M., Rizzi, J., & Burud, I. (2021). Hyperspectral and lidar data applied to the urban land cover machine learning and neural-network-based classification: A review. In Remote Sensing (Vol. 13, Issue 17). https://doi.org/10.3390/rs13173393.*
- *Kushwaha, S. K. P., Dayal, K. R., Singh, A., & Jain, K. (2019). Building facade and rooftop segmentation by normal estimation from UAV derived RGB point cloud. International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences - ISPRS Archives, 42(2/W17). https://doi.org/10.5194/isprs-archives-XLII-2-W17-173-2019.*
- *Li, X., & Liang, Y. (2015). Surface characteristics modeling and performance evaluation of urban building materials using LiDAR data. Applied Optics, 54(15). https://doi.org/10.1364/ao.54.004750.*
- *Ma, X., Zheng, G., Chi, X., Yang, L., Geng, Q., Li, J., & Qiao, Y. (2023). Mapping fine-scale building heights in urban agglomeration with spaceborne lidar. Remote Sensing of Environment, 285. https://doi.org/10.1016/j.rse.2022.113392.*
- *Margolis, R., Gagnon, P., Melius, J., Phillips, C., & Elmore, R. (2017). Using GIS-based methods and lidar data to estimate rooftop solar technical potential in US cities. Environmental Research Letters, 12(7). https://doi.org/10.1088/1748-9326/aa7225.*
- *Norman, M., Mohd Shafri, H. Z., Idrees, M. O., Mansor, S., & Yusuf, B. (2020). Spatio-statistical optimization of image segmentation process for building footprint extraction using very high-resolution WorldView 3 satellite data. Geocarto International, 35(10). https://doi.org/10.1080/10106049.2019.1573853.*
- *Olofsson, P., Foody, G. M., Herold, M., Stehman, S. V., Woodcock, C. E., & Wulder, M. A. (2014). Good practices for estimating area and assessing accuracy of land change. Remote Sensing of Environment, 148, 42–57. https://doi.org/10.1016/J.RSE.2014.02.015.*
- *Park, J., & Cho, Y. K. (2021). Laser Intensity-Assisted Construction Material Classification in Point Cloud Data Using Deep Learning. Computing in Civil Engineering 2021 - Selected Papers from the ASCE International Conference on Computing in Civil Engineering 2021. https://doi.org/10.1061/9780784483893.001.*

- *Rose, L. S. L. S., Akbari, H., & Taha, H. (2003). Characterizing the Fabric of the Urban Environment: A Case Study of Greater Houston, Texas. Lawrence Berkeley National Laboratory, December.*
- *Rutzinger, M., Höfle, B., Geist, T., & Stötter, J. (2006). Object-based building detection based on airborne laser scanning data within GRASS GIS environment. Proceedings of UDMS, 2006, 25th.*
- *Rutzinger, M., Rottensteiner, F., & Pfeifer, N. (2009). A comparison of evaluation techniques for building extraction from airborne laser scanning. IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing, 2(1), 11–20.*
- *Song, J.-H., Han, S.-H., Yu, K., & Kim, Y.-I. (2002). Assessing the possibility of land-cover classification using lidar intensity data. International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences - ISPRS Archives, 34.*
- *Taherzadeh, E., & Shafri, H. Z. M. (2013). Development of a Generic Model for the Detection of Roof Materials Based on an Object-Based Approach Using WorldView-2 Satellite Imagery. Advances in Remote Sensing, 02(04). https://doi.org/10.4236/ars.2013.24034.*
- *UN-HABITAT. (2012). State of the World's Cites 2012/2013: United Nations Human Settlements Programme. United Nations Human Settlements Programme (UN-HABITAT).*
- *Wang, C. K., & Hsu, P. H. (2007). Building Detection and Structure Line Extraction from Airborne LiDAR Data. Building, 12(1), 267 ff. http://jprs.geomatics.ncku.edu.tw/articlePDF/200712-12-4-365-379.pdf.*
- *Wang, J., Zang, D., Yu, J., & Xie, X. (2024). Extraction of Building Roof Contours from Airborne LiDAR Point Clouds Based on Multidirectional Bands. Remote Sensing, 16(1), 190.*
- *Xue, F., Lu, W., Tan, T., & Chen, K. (2020). Semantic enrichment of city information models with lidar-based rooftop albedo. Sustainable Buildings and Structures: Building a Sustainable Tomorrow - Proceedings of the 2nd International Conference in Sustainable Buildings and Structures, ICSBS 2019. https://doi.org/10.1201/9781003000716-27.*
- *Yi, P., Tong, P., & Zhao, Y. (2016). A decision tree classification method combining intensity and RGB value for LiDAR data. Communications in Computer and Information Science, 569. https://doi.org/10.1007/978-3-662-49155-3_17.*
- *Zhu, J., Huang, Z., Yue, X., & Liu, Z. (2023). Point Cloud Registration Based on Local Variation of Surface Keypoints. Electronics, 13(1), 35.*

Extracting Rooftops Types from Lidar data Using Geospatial techniques and Objective Classification for a Group of Neighborhoods in the City of Riyadh

Abstract:

This research aims to compare the accuracy of two different approaches for extracting building rooftops and classifying their types from LiDAR data in Riyadh, Saudi Arabia. The first approach is based on data processing into Geographic Information System (GIS) environment, while the second approach is based on object-oriented classification.

In the first approach, LiDAR data from 2012 was used to generate a Digital Surface Model (DSM) along with slope and aspect, reflection intensity values maps. The LiDAR points were then classified into three categories: ground, noise, and buildings. Following classification, two-dimensional building footprints were extracted, and the roof types were classified based on the corresponding reflection intensity values.

The second approach employed a combination of data including normalized Digital Surface Model (nDSM), intensity values, slope, and aspect. A multiresolution segmentation technique was applied to classify the data into two categories: building rooftops and background, using decision rules. Subsequently, three classification algorithms - Support Vector Machine (SVM), Decision Tree (DT), and Random Tree (RT) - were utilized to further classify the roof types into six categories: precast concrete roofs with gravel (differentiated as smooth and rough), ordinary concrete roofs (encompassing buildings and parking lots), tiled roofs, and other roof types.

The analysis revealed that GIS tools achieved an overall accuracy of 88% in extracting building rooftops. In comparison, object-oriented classification achieved an accuracy of 84.4%. This slight advantage for GIS tools can be attributed to the high spatial accuracy of the LiDAR data point coordinates. However, object-oriented classification algorithms demonstrated superior performance in classifying roof types. The RT algorithm achieved the highest overall accuracy (67%) and Kappa statistic (0.49). The overall lower accuracy in roof type classification can be attributed to the overlapping LiDAR intensity values among certain roof types.

Both approaches were effective in extracting building roofs, with GIS demonstrating a slight edge. However, object-oriented classification algorithms provided superior accuracy in classifying roof types. To further improve classification accuracy and overcome the limitations of each individual approach, it is recommended to integrate LiDAR data with high-resolution satellite imagery. Additionally, future research is warranted to develop more advanced classification techniques and explore the influence of other factors on classification accuracy, such as the specific characteristics of buildings and their surrounding environment.

key words: *LiDAR data, Building roofs, Roof types, GIS, Object-oriented classification, Riadh*