



Efektivitas Pengolahan Citra dengan Metode K-Nearest Neighbor dan Gray Level Co-Occurrence Matrix untuk Monitoring Pembajakan Tanah dengan Bajak Piring

The Effectivity of Image Processing Using K-Nearest Neighbor and Gray Level Co-Occurrence Matrix Method to Monitor Land Plowing Using Disc Plow

Setiyono, Hasna Afaf Faizah, Insan Sabri Helwandi, Hasbi Mubarak Suud*

Program Studi (S1) Ilmu Pertanian, Universitas Jember, Bondowoso, Indonesia

Penulis Korespondensi

Email: hasbimubarak@unej.ac.id

Abstrak. Salah satu teknologi monitoring yang banyak dikembangkan saat ini adalah teknik monitoring menggunakan drone. Pada penelitian ini dilakukan kajian untuk mengetahui efektivitas pengolahan citra hasil pembajakan tanah menggunakan bajak piring yang diambil menggunakan drone untuk monitoring hasil pembajakan menggunakan bajak piring. Metode pengolahan citra yang digunakan yaitu metode KNN (K-Nearest Neighbor) untuk menghitung luas area pembajakan berdasarkan klasifikasi rasio indeks warna RGB (Red, Green, Blue) dan metode GLCM (Gray Level Co-Occurance Matrix) untuk menganalisa tekstur citra guna menduga kedalaman pembajakan. Pada penelitian ini Metode KNN terbukti dapat megklasifikasikan area terbajak dan area tidak terbajak namun akurasi masih rendah. Semakin besar area yang tidak dibajak di lahan menyebabkan akurasi klasifikasinya juga semakin rendah. Sedangkan pada analisa dengan algoritma GLCM, ciri energi dan ciri entropi merupakan ciri yang paling baik untuk menduga kedalaman pembajakan karena memiliki koefisien korelasi (r) terbaik dibandingkan ciri statistic GLCM lainnya.

Kata kunci: bajak piring, GLCM, KNN, pengolahan citra, pembajakan tanah

Abstract. Monitoring area with drones is one of the monitoring technologies that are growing rapidly today. This study was conducted to determine the effectiveness of image processing with KNN (K-Nearest Neighbor) and GLCM (Gray Level Co-Occurance Matrix) to monitor land plowing using a disc plow implement. The image was taken using a drone. The KNN method is used to calculate the area that has been plowed by classifying the ratio of RGB (Red, Green, Blue) color index ratio. The GLCM method analyzes image textures to estimate the plowing depth. Based on this study, The KNN method was proven to classify the plowed areas and unplowed areas but the accuracy was still low. The more lands are unplowed, the accuracy of KNN gets lower. The best statistical characteristic of GLCM for estimating depth plowing is the characteristic of energy and entropy since it got the best correlation coefficient (r) of the others.

Keywords: GLCM, image processing, KNN, plate plows, land cultivation

1. Pendahuluan

Penerapan mekanisasi dalam pengolahan tanah di area pertanian dan perkebunan menggunakan traktor dan implemen bajak pada area lahan yang luas memiliki beberapa keuntungan yaitu lebih murah, efisien, dan cepat dibandingkan tanpa mekanisasi. Menurut

[Aldillah \(2016\)](#), mekanisasi pertanian dapat meningkatkan produktivitas dan efisiensi pengolahan tanah baik dari segi biaya operasi dan waktu. Namun terkadang sulit untuk melakukan pengawasan dan kontrol kualitas hasil pembajakan pada area lahan yang luas seperti pada operasi pengolahan lahan di lahan perkebunan dengan skala besar. Selain itu, pendeknya jeda antara waktu selesainya pengolahan tanah dan waktu mulai tanam menyebabkan waktu untuk audit hasil pembajakan tanah guna menilai prestasi kerja pengolahan tanah juga menjadi lebih singkat.

Monitoring melalui pengambilan citra menggunakan drone merupakan salah satu metode yang dapat digunakan untuk mengawasi proses pembajakan tanah pada area yang luas. Teknologi monitoring menggunakan drone menjadi pilihan alternatif disamping teknologi pemetaan lainnya seperti pemetaan dengan data berbasis satelit ([Hidayat & Mardiyanto, 2017](#)). Drone mampu terbang sesuai dengan mode perencanaan terbang (*autopilot*) karena dilengkapi dengan sistem kontrol penerbangan melalui sinyal GPS. Berdasarkan penelitian yang dilakukan oleh [Utomo \(2018\)](#), keunggulan penggunaan drone untuk percepatan monitoring lahan antara lain dapat menghasilkan citra dengan resolusi spasial yang besar, metode operasi mudah, dan tidak terkendala awan karena pengambilan citra dilakukan pada ketinggian di bawah awan.

Pengolahan tanah dengan bajak piring sudah banyak dilakukan dan seringkali dianggap memiliki kinerja yang lebih efisien karena menimbulkan gaya gesek lebih kecil pada operasinya. Bajak piring juga dapat beroperasi dimana bajak singkal tidak dapat beroperasi seperti pada tanah lekat, tanah kering dan keras, tanah kasar, tanah berbatu, dan lahan gambut berserasah ([Jamaluddin et al., 2019](#)). Bajak piring memiliki fungsi yang hampir sama dengan bajak singkal, yaitu memotong dan membalik tanah. Namun yang membedakan adalah terdapat mekanisme piringan yang dapat mengurangi gesekan dan tahanan tanah (*draft*) pada saat operasi ([Jamaluddin et al., 2019](#)). Timbulnya alur pembajakan (*furrow*) akibat dari pembajakan dapat memberikan perbedaan visual pada citra gambar. Perbedaan visual tersebut dapat dijadikan faktor yang membedakan kuantitas dan kualitas pembajakan tanah di lahan pertanian. Penelitian ini menggunakan metode pengolahan tiga spektrum band dari citra yaitu nilai *Red*, *Green*, dan *Blue*. Metode ini memiliki kelebihan yaitu mudah diaplikasikan, biaya operasional murah, dan mampu mendeteksi warna, bentuk, ukuran, tekstur permukaan, serta batas dari citra ([Hafeez et al., 2022](#)).

Salah satu metode yang dapat digunakan untuk mengidentifikasi warna dan tekstur dari citra uji tersebut adalah dengan menggunakan algoritma KNN (K-Nearest Neighbor) dan GLCM (Gray Level Co-Occurrence Matrices). Metode KNN merupakan teknik yang banyak digunakan dalam melakukan klasifikasi citra berdasarkan indeks warna RGB. KNN merupakan metode untuk mengklasifikasikan sebuah objek berdasarkan data terdekat dengan objek tersebut ([Angreni et al., 2019](#)). Sedangkan metode yang umum digunakan untuk menganalisa tekstur citra yaitu metode GLCM. GLCM memiliki fungsi menghitung kerapatan antar piksel yang memiliki nilai sama

(Bawono *et al.*, 2019). Metode KNN mempunyai keunggulan yaitu metode pelatihan yang cepat dan tahan terhadap data yang memiliki noise (Mutrofin *et al.*, 2014). Klasifikasi piksel citra tanah yang cenderung banyak memiliki noise dan keberagaman warna yang tidak begitu besar akan sesuai jika diklasifikasikan dengan metode KNN. Selain itu Metode KNN dan GLCM ini merupakan kombinasi yang saling mengisi karena metode GLCM memiliki kelemahan yaitu hanya menggunakan input *graycsale* sehingga komponen warna citra diabaikan sedangkan metode KNN membobotkan penilaian dari nilai warna citra (Ramadhani *et al.*, 2018). Penelitian ini akan mengkaji seberapa besar efektivitas penggunaan metode KNN dan GLCM untuk mengevaluasi hasil pembajakan lahan menggunakan bajak piring mencakup kesesuaian persentase area terbajak yang berhasil diklasifikasi dan kesesuaian nilai tekstur citra dengan data tingkat kedalaman pembajakan.

2. Bahan dan Metode

2.1. Waktu dan Tempat Penelitian

Penelitian dilakukan di lahan penelitian Universitas Jember Kampus Bondowoso, Kecamatan Curahdami, Kabupaten Bondowoso, Jawa Timur. Penelitian dilakukan pada bulan Juli hingga bulan Oktober 2021.

2.2. Bahan dan Alat Penelitian


Pembajakan menggunakan implement bajak piring Quick model D 3558 TR dengan 3 piringan bajak yang ditarik menggunakan traktor Quick A360 dengan daya 36 HP. Pengambilan citra menggunakan drone Dji Phantom 4 pro. Pengukuran kedalaman pembajakan menggunakan mistar kayu, waterpas, dan meteran. Pengolahan citra dilakukan dengan 2 buah *software* yaitu Matlab dan *ImageJ*. Komputer yang digunakan pada penelitian ini memiliki spesifikasi processor intel core i7, GPU Geforce NVIDIA 2 GB, dan RAM 12 Gb. Penyusunan algoritma KNN dan GLCM dilakukan menggunakan *software* Matlab untuk menghitung luasan pembajakan dan tingkat tekstur citra berdasarkan analisis luas piksel area terbajak. Sedangkan pengukuran luas area terbajak secara manual melalui pengukuran jumlah piksel pada area yang telah ditandai sebagai area terbajak diolah menggunakan *software* *ImageJ*.

2.3. Metode Pembajakan dan Pengambilan Citra Lahan

Lahan yang digunakan pada penelitian ini seluas 23 m x 22 m (506 m²). Pengambilan citra untuk pengujian algoritma KNN dilakukan dua kali. Pada citra uji 1, pembajakan hanya dilakukan pada area kecil yang dilakukan pada laham. Sedangkan pada citra uji 2 pembajakan dilakukan dengan menggunakan pola pembajakan bolak balik rapat seperti ditunjukkan pada [Gambar 1](#).

Setelah dilakukan pembajakan, lalu dilakukan pengukuran kedalaman pembajakan pada pada 21 titik koordinat yang merepresentasikan berbagai variasi kedalaman pembajakan yang


tersebar di seluruh area lahan. Pengambilan citra menggunakan drone diambil pada ketinggian 30 meter dengan posisi lensa tegak lurus terhadap bidang datar.



Gambar 1. Pola pembajakan bolak balik rapat yang digunakan pada penelitian ini

2.4. Metode Pengolahan Citra

Citra hasil tangkapan drone diolah dengan 3 metode yaitu metode KNN (*K-Nearest Neighbor*) untuk menghitung luas area pembajakan berdasarkan ekstraksi warna RGB (Red, Green, Blue) yang diolah menggunakan Matlab, metode manual untuk menghitung luas area terbajak berdasarkan penanda garis vektor yang diolah menggunakan ImageJ, dan metode GLCM (*Gray Level Co-Occurance Matrix*) untuk menduga kedalaman pembajakan melalui analisa tekstur citra yang diolah menggunakan Matlab. Metode KNN bertujuan untuk melakukan klasifikasi citra pada piksel yang jaraknya paling dekat dengan objek tersebut. Metode ini adalah salah satu metode pembelajaran yang mengambil pendekatan lokal dimana semua perhitungan ditahan hingga proses algoritma selesai (Subairi *et al.*, 2018). Nilai K yang digunakan dalam penelitian ini sebesar 5. Nilai K tersebut didapatkan dari optimasi hasil pengujian pada citra uji dimana hasil pengujian nya stabil dan optimal pada nilai K lebih besar dari 4. Sehingga untuk optimasi waktu proses dan akurasi pengolahan data citra uji maka dipilih nilai K sebesar 5.



Gambar 2. Citra latih untuk klasifikasi (a) lahan sudah terbajak dan (b) lahan sudah terbajak

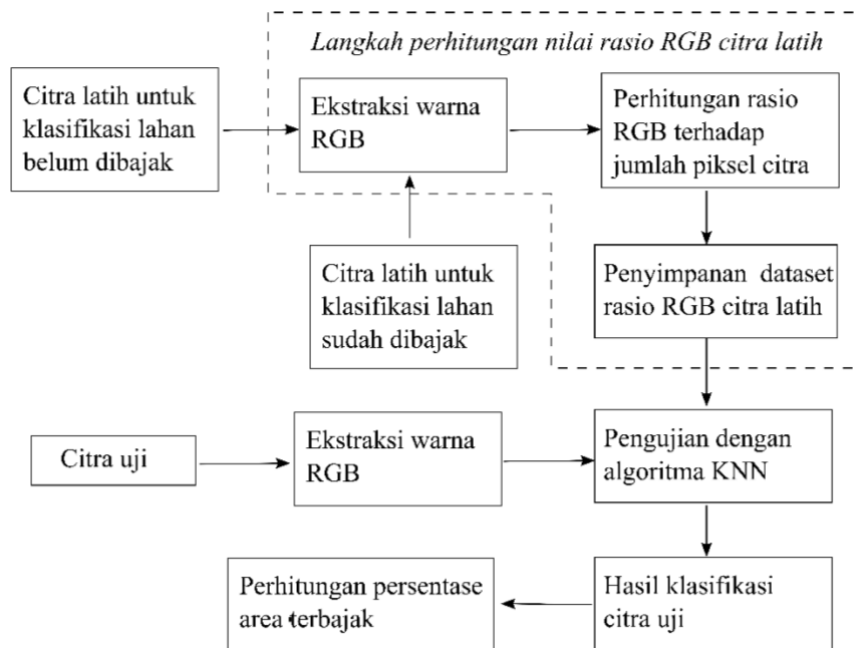
Proses pembelajaran pada metode KNN menggunakan 2 jenis citra latih, yaitu citra latih untuk klasifikasi lahan tidak terbabak dan citra latih untuk klasifikasi lahan sudah terbabak. Terdapat 18 buah sampel citra latih untuk klasifikasi lahan tidak terbabak dan 11 buah sampel citra latih untuk klasifikasi lahan sudah terbabak. Kedua jenis citra latih tersebut lalu diekstraksi nilai rasio RGB menggunakan persamaa (1), (2), dan (3).

$$Rasio\ Red = \frac{\sum Ekstraksi\ Red}{\sum\ Pixels} \dots\dots\dots (1)$$

$$Rasio\ Green = \frac{\sum Ekstraksi\ Green}{\sum\ Pixels} \dots\dots\dots (2)$$

$$Rasio\ Blue = \frac{\sum Ekstraksi\ Blue}{\sum\ Pixels} \dots\dots\dots (3)$$

Citra latih untuk lahan tidak terbabak dipilih dengan ciri masih adanya vegetasi rumput dan gulma lainnya, sedangkan citra latih untuk lahan sudah terbabak dipilih dengan ciri warna mayoritas tanah yang lebih gelap seperti terlihat pada Gambar 2. Hasil nilai ekstraksi rasio RGB dari citra latih digunakan untuk menentukan karakteristik klasifikasi pengujian guna menghitung luas area lahan yang terbabak pada citra uji. Tahapan implementasi metode KNN pada penelitian dapat dilihat pada Gambar 3.



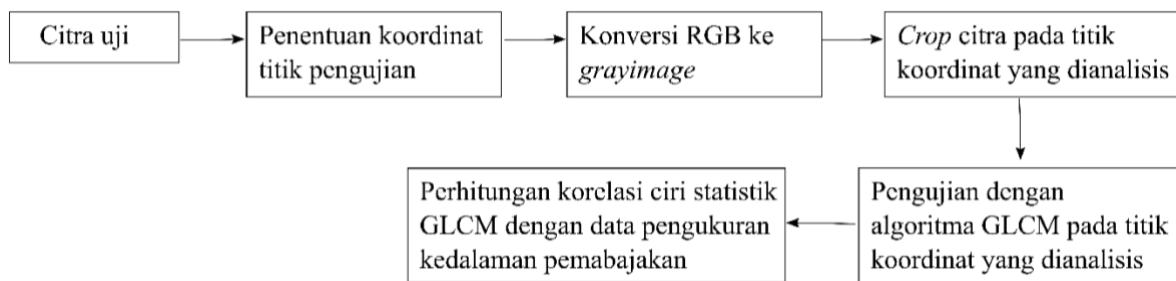
Gambar 3. Tahapan pengolahan citra dengan KNN

Hasil pengolahan citra hasil dari metode KNN selanjutnya dibandingkan dengan pengolahan citra secara manual menggunakan software ImageJ. Titik-titik terluar area terbabak yang terlihat di citra uji dan telah diverifikasi di lapangan dihubungkan pada sebuah area garis vektor warna kuning menggunakan software ImageJ sehingga tampak luasan dari area terbabak. Luas area tersebut lalu dihitung luasnya menggunakan fungsi yang ada dalam software ImageJ sehingga

didapatkan jumlah piksel dari area terbajak. Hasil analisa dari metode KNN dan metode manual ditampilkan dalam bentuk persentase area terbajak yang dihitung berdasarkan persamaan (4).

$$\text{Persentase area terbajak (\%)} = \frac{\text{Jumlah piksel dengan klasifikasi area terbajak}}{\text{Jumlah total piksel keseluruhan citra uji}} \times 100\% \dots\dots\dots (4)$$

Metodel GLCM adalah salah satu metode analisis tekstur pada citra. Tekstur merupakan ciri dari suatu citra yang dapat dikenali secara visual tetapi sulit untuk diidentifikasi dan dikuantifikasi, namun dapat dikenali secara statistik dengan membandingkan kepadatan kelompok piksel pada suatu citra (Lusiana *et al.*, 2019). Ekstraksi citra dengan metode GLCM akan menghasilkan lima ciri statistik yaitu ciri kontras, ciri korelasi, ciri homogenitas, ciri energi, dan ciri entropi. Ciri statistik tersebut didapatkan dengan menghitung kekuatan hubungan antara dua piksel pada jarak dan pada orientasi sudut tertentu (Ramadhani *et al.*, 2018). Pada penelitian ini nilai ciri statistik yang didapatkan merupakan nilai rata-rata dari operasi GLCM dengan jarak 1 piksel pada orientasi sudut 0°, 45°, 90°, dan 135°. Tahapan operasi metode GLCM pada penelitian ini ditunjukkan pada Gambar 4. Selanjutnya hasil analisa tekstur citra dengan metode GLCM menggunakan software Matlab dibandingkan dengan data pengukuran kedalaman pembajakan yang dilakukan di lahan sehingga didapatkan hubungan korelasi diantara analisa tekstur citra dan kedalaman pembajakan.



Gambar 4. Tahapan pengolahan citra dengan GLCM

3. Hasil dan Pembahasan

Pembajakan dilakukan pada petak lahan yang telah disiapkan. Terdapat dua kali pembajakan yang menghasilkan citra uji 1 dan citra uji 2. Citra uji 1 dan citra uji 2 adalah citra yang akan diuji klasifikasi menggunakan algoritma KNN. Sedangkan untuk aplikasi algoritma GLCM guna mencari tekstur citra untuk menduga kedalaman pembajakan dilakukan pada citra uji 2 saja. Algoritma metode KNN dan GLCM ditulis menggunakan software Matlab. Tahap pertama dari pengolahan citra dengan metode KNN dimulai dengan mengekstrak nilai rasio RGB citra latih pada Gambar 2 dengan menggunakan Persamaan (1), (2), dan (3) sehingga didapatkan nilai rasio RGB ciri latih seperti yang ditunjukkan pada Tabel 1. Data pada Tabel 1 tersebut digunakan

sebagai ciri latih untuk melakukan klasifikasi pada citra uji 1 dan citra uji 2 menggunakan metode KNN. Sebagai pembanding hasil klasifikasi menggunakan algoritma KNN, maka dilakukan klasifikasi citra secara manual dengan memberikan penanda garis vektor warna kuning pada area terbajak sesuai dengan pengamatan visual ketika ada di lahan. Area di dalam penanda warna kuning tersebut akan dihitung sebagai luas piksel area yang telah terbajak menggunakan fungsi dalam software ImageJ.

Tabel 1. Nilai ekstraksi rasio red, green, blue terhadap luas piksel untuk gambar ciri latih

No.	Ciri latih sebelum bajak			Ciri latih setelah bajak		
	<i>Rasio (Red)</i>	<i>Rasio (Green)</i>	<i>Rasio (Blue)</i>	<i>Rasio (Red)</i>	<i>Rasio (Green)</i>	<i>Rasio (Blue)</i>
1	0,33	0,36	0,32	0,54	0,51	0,48
2	0,32	0,37	0,28	0,44	0,39	0,36
3	0,29	0,30	0,25	0,44	0,38	0,35
4	0,38	0,40	0,33	0,45	0,38	0,35
5	0,35	0,39	0,32	0,45	0,36	0,33
6	0,37	0,41	0,32	0,39	0,30	0,28
7	0,32	0,37	0,27	0,42	0,34	0,31
8	0,29	0,29	0,20	0,42	0,34	0,31
9	0,43	0,47	0,33	0,39	0,30	0,27
10	0,34	0,36	0,28	0,49	0,43	0,40
11	0,36	0,36	0,26	0,45	0,37	0,34
12	0,37	0,39	0,26			
13	0,35	0,40	0,26			
14	0,39	0,40	0,29			
15	0,38	0,44	0,36			
16	0,38	0,43	0,33			
17	0,39	0,43	0,35			
18	0,31	0,35	0,31			


Hasil klasifikasi citra untuk mengetahui area terbajak pada citra uji 1 dan citra uji 2 ditunjukkan pada [Gambar 5](#) dan [Gambar 6](#). Pada [Gambar 5 dan 6](#) bagian (a) merupakan hasil klasifikasi citra uji menggunakan metode KNN dimana piksel yang diklasifikasikan sebagai area tidak terbajak dirubah menjadi warna putih untuk membedakan dengan piksel diklasifikasikan sebagai area terbajak. Sedangkan pada [Gambar 5 dan 6](#) bagian (b), menunjukkan hasil klasifikasi secara manual menggunakan penanda vektor kuning pada software ImageJ dimana luas area terbajak adalah area di bagian dalam garis vektor warna kuning.

Hasil pendeteksian area yang telah terbajak baik menggunakan metode KNN ataupun secara manual ditampilkan pada [Tabel 2](#). Persentase area terbajak yang ditampilkan tersebut merupakan perbandingan jumlah piksel area terbajak terhadap jumlah total piksel pada citra uji

yang dihitung menggunakan Persamaan (4). Dapat dilihat bahwa perbedaan terbesar terdapat pada hasil klasifikasi citra uji 1 dimana perbedaan antara 2 metode klasifikasi tersebut sebesar 36%. Sedangkan pada citra uji 2 didapatkan perbedaan antara kedua metode klasifikasi tersebut sebesar 14%.



Gambar 5. Hasil klasifikasi citra uji 1 (a) dengan metode KNN dan (b) dengan metode manual menggunakan penanda garis vektor warna kuning



Gambar 6. Hasil klasifikasi citra uji 2 (a) dengan metode KNN dan (b) dengan metode manual menggunakan penanda garis vektor warna kuning

Tabel 2. Persentase area terbajak menggunakan metode KNN dan metode manual

Nama Citra Uji	Metode Klasifikasi	
	Metode KNN (Software Matlab)	Metode Manual (Software ImageJ)
Citra Uji 1	39%	3%
Citra Uji 2	68%	54%

Perbedaan hasil yang didapatkan diantara dua metode ini masih cukup besar terutama pada citra uji 1. Banyak piksel pada area lahan tidak terbajak diklasifikasikan oleh metode KNN sebagai piksel area terbajak seperti terlihat pada **Gambar 5 (a)**, sehingga menyebabkan persentase area terbajak pada citra uji 1 menjadi lebih besar daripada hasil persentase area terbajak menggunakan metode manual. Pada citra uji 2 sebenarnya juga banyak piksel yang diklasifikasikan oleh metode KNN sebagai area tidak terbajak tetapi karena jumlah area tidak terbajak nya lebih kecil sehingga

hasil persentase area terbajaknya mendekati hasil persentase area terbajak menggunakan metode manual.

Metode KNN ini terbukti dapat melakukan klasifikasi area sudah terbajak dan belum terbajak, namun terdapat keterbatasan klasifikasi metode KNN yang hanya didasarkan pada nilai rasio *red*, *green*, dan *blue*. Hal ini bisa terjadi karena banyak piksel pada area tidak terbajak memiliki rasio *red*, *green*, dan *blue* (RGB) yang mirip dengan piksel area sudah terbajak sehingga menyebabkan banyak area yang seharusnya menjadi area tidak terbajak malah diklasifikasikan sebagai area terbajak. Sifat operasi analisa citra dengan algoritma KNN ini bertumpu pada input dari indeks rasio warna RGB mengakibatkan rentan pada indeks rasio RGB yang mirip pada citra uji (Bhatia & Vandana, 2010).

Pada operasi algoritma GLCM pada citra uji 2, dilakukan pengukuran nilai tekstur citra pada 21 titik koordinat seperti tampak pada Gambar 7. Pengukuran kedalaman dilakukan juga pada 21 titik koordinat tersebut yang digunakan sebagai pembanding data nilai tekstur citra pada titik titik tersebut. Semua 21 titik koordinat yang dipilih telah yang mewakili berbagai variasi kedalaman pembajakan dan tersebar pada seluruh area pembajakan. Operasi pengolahan citra dengan metode GLCM pada penelitian ini menghasilkan nilai ciri statistik GLCM yaitu ciri kontras, ciri korelasi, ciri homogenitas, ciri energi, dan ciri entropi (Ilham & Pasnur, 2018). Kelima ciri tersebut menggambarkan tekstur citra uji pada titik titik koordinat tersebut. Data kedalaman pembajakan yang diukur langsung di lahan dibandingkan dengan data lima ciri statistik tersebut sehingga didapatkan nilai koefisien relasi (r) yang menunjukkan seberapa kuat korelasi antara kedua data pengukuran tersebut. Besarnya koefisien korelasi tersebut ditampilkan dalam Tabel 3.



Gambar 7. Titik lokasi pengambilan data kedalaman pembajakan

Tabel 3. Koefisien korelasi (r) antara nilai ciri statistik GLCM dengan data pengukuran kedalaman pembajakan

	Koefisien Korelasi (r)				
	Ciri Kontras	Ciri Homogenitas	Ciri Energi	Ciri Korelasi	Ciri Entropi
Kedalaman Pembajakan	-0,51	0,61	0,74	-0,08	-0,73

Berdasarkan data yang didapatkan pada [Tabel 3](#) diketahui bahwa nilai r pada setiap ciri statistik GLCM memiliki nilai yang beragam. Nilai koefisien korelasi (r) terendah terdapat pada parameter ciri korelasi. Semakin dalam pengoperasian bajak piring maka akan meninggalkan jejak alur pembajakan semakin besar. Alur pembajakan yang semakin besar tersebut jika tertangkap pada citra drone, akan menciptakan banyak pasangan warna RGB piksel yang terpusat pada satu koordinat pada area tersebut. Semakin banyak pasangan piksel yang terpusat pada satu area koordinat akan menyebabkan nilai parameter energi meningkat. Gulma dan rumput cenderung hilang dan tidak terlihat pada tanah yang dibajak lebih dalam sehingga menyebabkan nilai piksel pada area tersebut semakin seragam dan variasi intensitas citra menjadi semakin konstan. Semakin rendahnya variasi intensitas citra juga menyebabkan nilai homogenitas semakin tinggi ([Lusiana et al., 2019](#)). Hal tersebut menyebabkan ciri energi dan ciri homogenitas memiliki korelasi positif terhadap data kedalaman pembajakan. [Mira et al., \(2017\)](#) dan [Praseptiyana et al. \(2019\)](#) menyatakan semakin kecil perbedaan piksel satu dengan piksel lain yang berdekatan akan menyebabkan citra semakin konstan sehingga menghasilkan nilai kontras yang semakin kecil. Sedangkan nilai entropi semakin mendekati satu menunjukkan semakin tinggi tingkat kekasaran citra. Pada tanah yang dibajak lebih dalam akan menghasilkan citra yang cenderung seragam dan lebih gelap di area tersebut sehingga menyebabkan nilai kontras dan entropi pada area tersebut semakin kecil dan memiliki korelasi negatif dengan data kedalaman pembajakan.

Meskipun hubungan korelasi diantara ciri kontras, ciri homogenitas, ciri energi, dan ciri entropi terhadap kedalaman pembajakan telah dapat dijelaskan, namun nilai koefisien korelasi (r) yang didapatkan tidak cukup besar, hanya berkisar antara 0,51 hingga 0,74 untuk parameter kontras, homogenitas, energi, dan entropi. Bahkan koefisien korelasi (r) untuk ciri korelasi, nilainya sangat rendah hanya sebesar -0,08. Dari data tersebut maka ciri entropi dan ciri energi merupakan ciri statistic GLCM yang paling baik digunakan untuk menduga kedalaman pembajakan tanah karena memiliki hubungan korelasi terbaik diantara ciri statistik lainnya. Beberapa hal yang dapat digunakan untuk memperkuat koefisien korelasi (r) diantara parameter tersebut antara lain dengan menggunakan citra uji yang mempunyai kerapatan piksel lebih tinggi. Salah satu cara untuk mendapatkan citra dengan kerapatan lebih tinggi yaitu dengan mengurangi ketinggian drone ketika melakukan pengambilan citra. Selain itu juga dapat dengan menambahkan

teknik klasifikasi lain bersama dengan GLCM seperti *dominant color descriptor* (DCD), *multi-scale dense sift* (MDSIFT), dan *scalable color descriptor* (SCD) seperti yang dilakukan oleh He *et al.* (2014) yang dapat meningkatkan akurasi klasifikasi sebesar 22% dibandingkan kombinasi fitur lainnya.

4. Kesimpulan

Metode KNN terbukti dapat mengklasifikasikan mana area terbajak dan area tidak terbajak tetapi dalam penelitian ini masih banyak klasifikasi yang kurang akurat karena keterbatasan metode yang hanya berdasarkan kanal tampak *red*, *green*, dan *blue*. Pada penelitian ini perbedaan persentase area terbajak yang dicari berdasarkan metode KNN yang dijalankan pada Matlab dan metode manual menggunakan ImageJ pada citra uji 1 sebesar 36% dan pada citra uji 2 sebesar 14%. Semakin besar area yang tidak dibajak, tingkat keakurasian metode KNN ini juga semakin rendah. Sedangkan analisa citra metode GLCM untuk menganalisa tekstur tanah memiliki koefisien korelasi (r) paling tinggi pada ciri energi dan ciri entropi. Kedua ciri statistik GLCM ini dapat digunakan sebagai ciri paling efektif untuk menduga kedalaman pembajakan. Pada penelitian selanjutnya perlu dilakukan kajian tentang metode ekstraksi warna dan klasifikasi yang dapat digunakan bersama dengan metode GLCM dan KNN guna meningkatkan akurasi dari klasifikasi dan analisa tekstur citra untuk mengevaluasi pembajakan tanah.

Daftar Pustaka

- Aldillah, R. (2016). Kinerja Pemanfaatan Mekanisasi Pertanian dan Implikasinya dalam Upaya Percepatan Produksi Pangan di Indonesia. *Forum Penelitian Agro Ekonomi*, 34(2), 163. <https://doi.org/10.21082/fae.v34n2.2016.163-171>
- Angreni, I. A., Adisasmita, S. A., Ramli, I., & Sumarni, H. (2019). Pengaruh Nilai K Pada Metode K-Nearest Neighbor (KNN) Terhadap Tingkat Akurasi Identifikasi Kerusakan Jalan. *Rekayasa Sipil*, 7(2), 63–70. <https://doi.org/10.22441/JRS.2018.V07.I2.01>
- Bawono, A. W., Hidayat, B., & Nugroho, S. (2019). Deteksi Area Hutan Berbasis Citra Google Earth Menggunakan Metode Grey-level-co-occurrence Matrix (glcm) Dan Support Vector Machine (svm). *EProceedings of Engineering*, 6(1). <https://openlibrarypublications.telkomuniversity.ac.id/index.php/engineering/article/view/8702>
- Bhatia, N., & Vandana. (2010). Survey of Nearest Neighbor Techniques. *(IJCSIS) International Journal of Computer Science and Information Security*, 8(2), 302–305. https://www.researchgate.net/publication/44288385_Survey_of_Nearest_Neighbor_Techniques
- Hafeez, A., Husain, M. A., Singh, S. P., Chauhan, A., Khan, M. T., Kumar, N., Chauhan, A., & Soni, S. K. (2022). Implementation of drone technology for farm monitoring & pesticide spraying: A review. *Information Processing in Agriculture*. <https://doi.org/10.1016/J.INPA.2022.02.002>
- He, Y., Xu, C., Khanna, N., Boushey, C. J., & Delp, E. J. (2014). Analysis of Food Images: Features And Classification. *Proceedings. International Conference on Image Processing, 2014*, 2744. <https://doi.org/10.1109/ICIP.2014.7025555>
- Hidayat, R., & Mardiyanto, R. (2017). Pengembangan Sistem Navigasi Otomatis Pada UAV (Unmanned Aerial Vehicle) dengan GPS (Global Positioning System) Waypoint. *Jurnal*

- Teknik ITS*, 5(2). <https://doi.org/10.12962/J23373539.V5I2.16342>
- Ilham, & Pasnur. (2018). Aplikasi Pengolah Citra Untuk Menentukan Jenis Tanah Pada Lahan Pertanian. *Inspiration: Jurnal Teknologi Informasi Dan Komunikasi*, 8(2), 89–96. <https://doi.org/10.35585/INSPIR.V8I2.2464>
- Jamaluddin, Syam, H., Lestari, N., & Rizal, M. (2019). *Alat dan Mesin Pertanian*. Badan Penerbit Univeritas Negeri Makassar. [http://eprints.unm.ac.id/17661/2/Buku Monograf - Alat dan Mesin Pertanian.pdf](http://eprints.unm.ac.id/17661/2/Buku_Monograf_-_Alat_dan_Mesin_Pertanian.pdf)
- Lusiana, V., Al Amin, I. H., Hartono, B., & Kristianto, T. (2019, July 24). Ekstraksi Fitur Tekstur Menggunakan Matriks Glem Pada Citra Dengan Variasi Arah Obyek. *Seminar Nasional Multi Disiplin Ilmu*. <https://www.unisbank.ac.id/ojs/index.php/sendu/article/view/7398>
- Mira, M. B., Ana, A., & Ari Hidayat, S. (2017). Implementasi Algoritma GLCM Dan MED pada Aplikasi Pendeteksi Kolesterol Melalui Iris Mata. *Multimedia Artificial Intelligent Networking Database Journal*, 2(2), 23–42. <https://doi.org/10.26760/MINDJOURNAL.V2I2.23-42>
- Mutrofin, S., Izzah, A., Kurniawandhani, A., & Masrus, M. (2014). Optimasi Teknik Klasifikasi Modified K Nearest Neighbor Menggunakan Algoritma Genetika. *Journal GAMMA*, 10(1), 130–134. <https://ejournal.umm.ac.id/index.php/gamma/article/view/2493>
- Praseptiyana, W. I., Widodo, A. W., & Rahman, M. A. (2019). Pemanfaatan Ciri Gray Level Co-occurrence Matrix (GLCM) Untuk Deteksi Melasma Pada Citra Wajah. *Jurnal Pengembangan Teknologi Informasi Dan Ilmu Komputer*, 3(11), 10402–10409. <https://j-ptiik.ub.ac.id/index.php/j-ptiik/article/view/6685>
- Ramadhani, M., Suprayogi, S., & Dyah, B. H. (2018). Klasifikasi Jenis Jerawat Berdasarkan Tekstur Dengan Menggunakan Metode GLCM. *E-Proceeding of Engineering*, 870–876. <https://core.ac.uk/download/pdf/299921075.pdf>
- Subairi, Rahmadwati, & Yudaningtyas, E. (2018). Implementasi Metode k-Nearest Neighbor pada Pengenalan Pola Tekstur Citra Saliva untuk Deteksi Ovulasi. *Jurnal EECCIS*, 12, 9–14. <https://jurnaleeccis.ub.ac.id/index.php/eeccis/article/view/464>
- Utomo, B. (2018). Drone Untuk Percepatan Pemetaan Bidang Tanah. *Media Komunikasi Geografi*, 18(2), 146–155. <https://doi.org/10.23887/MKG.V18I2.12798>