

ALGORITMA MACHINE LEARNING DETEKSI DEFORESTASI HUTAN HUJAN TROPIS DI KABUPATEN KOTAWARINGIN BARAT

(Machine Learning Algorithm Detection of Tropical Rain Forest Deforestation in Kotawaringin Barat Regency)

Beni Iskandar, Nanang Hanafi

Department Forestry, Muhammadiyah University of Palangkaraya
Jl. RTA Amilono 1.5, Kota Palangkaraya, Kalimantan Tengah, INDONESIA

Email: beniiskandar@umpr.ac.id, nananghanafi@umpr.ac.id

Abstract

Deforestasi hutan hujan tropis sangat ekstensif dan permanen menyebabkan degradasi hilangnya keanekaragaman hayati, penurunan kualitas dan kuantitas air, polusi udara dan emisi CO². Beberapa dekade terakhir telah berkembang signifikan penerapan ekstraksi penutupan lahan pada citra secara otomatis dengan teknik Machine Learning (ML). Penelitian ini bertujuan mengkomparasi ML algoritma RF, CART dan SVM untuk deteksi deforestasi dan identifikasi penutupan lahan hutan hujan tropis di Kabupaten Kotawaringin Barat. Penelitian ini menggunakan citra Landsat-7 perekaman tahun 2000 dan citra Sentinel-2A perekaman tahun 2021, saluran parameter spektral klasifikasi yang digunakan yaitu biru, merah, hijau, infra merah dekat dan gelombang pendek infra merah 1 dan 2, deteksi deforestasi menggunakan tiga ML algoritma yaitu RF, CART dan SVM. Hasil penelitian ini menunjukkan bahwa penutupan hutan alam mengalami penurunan seluas 180.073 ha dan laju deforestasi 24.975 ha/th atau 1.9 %/th yang terjadi antara tahun 2000 hingga 2021. Algoritma RF menunjukkan hasil yang terbaik untuk deteksi deforestasi hutan hujan tropis di Kabupaten Kotawaringin Barat dengan rerata akurasi OA 95% dan Kappa 94%.

Keywords: Deforestasi Hutan Hujan Tropis, Penutupan Lahan, Machine Learning, Random Forest, Classification and Regression Trees, Support Vector Machine

1. PENDAHULUAN

Deforestasi hutan hujan tropis sangat ekstensif dan permanen menyebabkan degradasi hilangnya keanekaragaman hayati, penurunan kualitas dan kuantitas air, polusi udara dan emisi CO² yang menginduksi gas rumah kaca sehingga terjadi perubahan iklim global [1]. Hutan hujan tropis Indonesia telah mengalami deforestasi disebabkan oleh kebakaran hutan dan lahan, perluasan perkebunan sawit dan industri *pulp* kayu [2]–[5]. Deforestasi hutan hujan tropis Kabupaten Kotawaringin Barat banyak dipengaruhi oleh kegiatan penebangan hutan atau berkembangnya industri pemanfaatan hutan alam, sedangkan perubahan skala besar menjadi area perkebunan sawit telah terjadi baru-baru ini [3], [6].

Penginderaan jauh adalah teknologi yang cocok, hemat biaya, dan tepat waktu memetakan dan memantau hutan yang luas, dibandingkan dengan survei terestrial yang memakan waktu dan mahal [7], [8]. Data penginderaan jauh telah dilegalkan sebagai salah satu sumber data untuk memetakan dan

memantau perubahan penutupan lahan dari waktu ke waktu seperti citra Landsat [4], [9]. Penelitian mengenai pemetaan, pemantauan dan peramalan dinamika penutupan lahan telah dilakukan dengan memanfaatkan data penginderaan jauh citra resolusi spasial rendah, menengah dan tinggi, dengan kemajuan sensor satelit, teknologi penginderaan jauh sangat penting untuk bidang penelitian dan tujuan perencanaan [10].

Deteksi deforestasi hutan pada citra dilakukan dengan metode visual atau panca indra penglihatan untuk membedakan objek [11], metode ini memiliki kelebihan dan kekurangan. Kelebihan metode ini menghasilkan akurasi klasifikasi penutupan lahan yang tinggi, sedangkan kekurangan metode ini yaitu akurasi klasifikasi bergantung pada pengalaman dari seorang operator dan perlu waktu lama atau tidak efisien [11]. Sehingga diperlukan algoritma praktis yang tersedia untuk mendeteksi deforestasi hutan.

Beberapa dekade terakhir telah berkembang signifikan penerapan ekstraksi penutupan lahan pada citra secara otomatis dengan teknik *Machine Learning* (ML). Keunggulan dari teknik ini ekstraksi data cepat

dan akurasi tinggi [12], [13]. Beberapa ML algoritma yang populer yaitu Algoritma *Random Forest* (RF), *Classification and Regression Trees* (CART), dan *Support Vector Machine* (SVM) [14]–[16]. Deskripsi ke tiga algoritma ini sebagai berikut (1) RF adalah algoritma yang mengimplementasikan *bootstrap aggregating* (*bagging*) dan *random feature selection* [17], dalam RF banyak pohon ditumbuhkan sehingga terbentuk hutan, tiap pohon menghasilkan satu klasifikasi penutupan lahan, kalkulasi akhir penutupan lahan ditentukan dari suara terbanyak (*majority vote*), (2) CART adalah algoritma non-parametrik yang memproduksi sebuah pohon keputusan berupa binary tree. Pohon keputusan dapat berupa pohon klasifikasi kelas kategori atau pohon regresi kelas numerik [18], algoritma ini telah banyak di aplikasi dalam penginderaan jauh [15], [19], (3) SVM adalah teknik klasifikasi untuk menemukan *hyperplane* di ruang dimensi tinggi yang memisahkan data pelatihan ke dalam kelas-kelas sehingga anggota kelas terpisah secara maksimal [20].

Algoritma RF, CART dan SVM banyak digunakan untuk mendeteksi penutupan lahan seperti penutupan sawit, kebakaran hutan, dan pemantauan hutan di lanskap Boreal. Ketiga algoritma ini memiliki ke akurat yang tinggi pada studi kasus yang berbeda, algoritma RF mendeteksi deforestasi hutan di wilayah pesisir akurat sebesar 97% [21], algoritma CART untuk pemetaan area kebakaran hutan berbasis Landsat-8 dan Sentinel-2 menunjukkan bahwa akurasi sebesar 97% [15], dan algoritma SVM untuk pemetaan kelapa sawit di Malaysia menunjukkan bahwa akurasi sebesar 93% [14]. Uraian ini menjadi pertimbangan penulis menggunakan algoritma RF, CART dan SVM yang sangat cocok mendeteksi objek berbasis lahan. Penulis akan membandingkan atau mengkomparasi akurasi ke tiga algoritma tersebut dalam studi kasus deteksi deforestasi dan identifikasi penutupan lahan hutan hujan tropis di Kabupaten Kotawaringin Barat, sehingga akan didapatkan satu algoritma yang praktis dan akurat untuk mendeteksi deforestasi hutan hujan tropis di Kabupaten Kotawaringin Barat. Dengan demikian, penelitian ini bertujuan untuk mengkomparasi algoritma ML yaitu RF, CART, dan SVM deteksi deforestasi dan identifikasi penutupan lahan hutan hujan tropis di Kabupaten Kotawaringin Barat.

2. TINJAUAN PUSTAKA

Penelitian terdahulu menggunakan ML algoritma RF untuk menganalisis penutupan lahan dan memantau perubahan hutan dari tahun 2000 hingga

2019 dan mensimulasikan pembangunan hutan di masa depan di Kawasan hutan hujan tropis yang terletak di Brasil. Citra yang digunakan multi sumber yaitu citra Landsat-5, Landsat-7, Landsat-8 dan Sentinel-2. Penelitian ini menggunakan ML algoritma *Random Forest* (RF) untuk mengklasifikasikan kelas penutupan dan bukan kelas penutupan hutan. Hasil penelitian ini menunjukkan bahwa akurasi kappa 95-96%, dengan demikian akurasi dari algoritma RF memberikan hasil yang baik untuk klasifikasi penutupan lahan [21].

Algoritma CART telah digunakan dalam penelitian evaluasi perubahan penutupan lahan di Kawasan pesisir menggunakan citra Landsat perekaman tahun 1990 sampai dengan tahun 2020. Hasil penelitian ini menunjukkan bahwa akurasi dari algoritma CART 90.9% [22]. Penelitian evaluasi penggunaan lahan Kawasan lahan basah menggunakan multitemporal citra Landsat 3 perekaman tahun 1978, Landsat-5 perekaman tahun 1991, Landsat-7 perekaman tahun 2001, dan Landsat-8 perekaman tahun 2014, hasil penelitian ini menunjukkan akurasi klasifikasi 96.9% [23].

Algoritma SVM telah digunakan untuk klasifikasi secara otomatis di ekosistem mangrove menggunakan multitemporal citra Landsat 5, Landsat 7 dan Landsat-8 perekaman tahun 2001 sampai dengan 2020. Hasil penelitian ini menunjukkan bahwa akurasi SVM berkerja dengan baik untuk mengklasifikasi hutan mangrove dengan akurasi 93% sampai dengan 96%[24]

Penelitian terdahulu juga telah mencoba membandingkan kehandalan algoritma ML algoritma RF, CART, dan SVM pada kasus pemetaan kelapa sawit, identifikasi kebakaran hutan, pemantauan hutan pada lanskap Boreal. Berdasarkan kajian literatur, perlu penelitian yang menguji kehandalan ML algoritma RF, CART, SVM untuk memantau hutan hujan tropis yang berada di Kabupaten Kotawaringin Barat. Aplikasi penerapan ML ini upaya otomatisasi pemantauan hutan hujan tropis yang berguna untuk deforestasi dan identifikasi penutupan lahan hutan hujan tropis di Kabupaten Kotawaringin Barat, Kalimantan Tengah.

3. METODE PENELITIAN

3.1 Alat dan Bahan

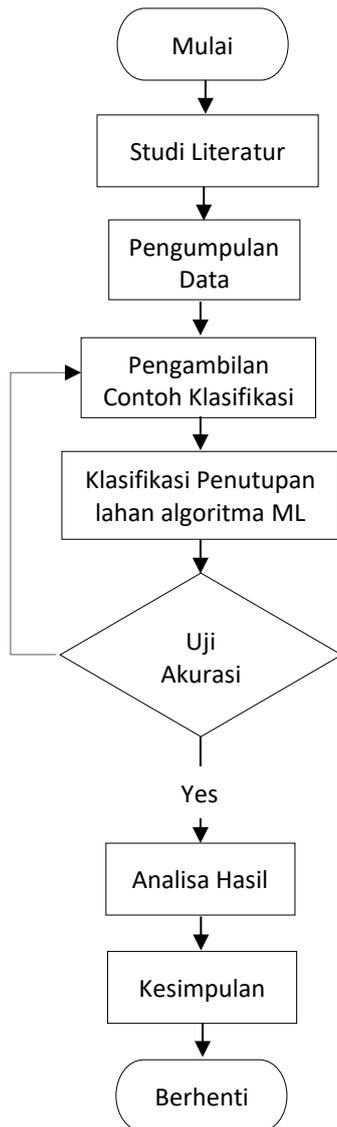
Alat dan bahan yang digunakan dalam penelitian ini sebagai berikut:

- a. Laptop (Intel Qore i3 dengan RAM 4 GB)
- b. Sistem operasi windows 10 64 bit
- c. *Google Earth Engine* (GEE) *cloud computing*
- d. ArcGIS 10.8

- e. Citra Landsat-7 perekaman tahun 2000 dan citra Sentinel-2A perekaman tahun 2021 resolusi spasial (30 m) menggunakan saluran biru, merah, hijau, infra merah dekat, gelombang pendek infra merah 1 dan 2.
- f. Batas administrasi Kabupaten Kotawaringin Barat

Kotawaringin Barat. *Ketiga*, pengambilan data contoh klasifikasi berdasarkan kelas penutupan lahan. *Keempat*, melakukan klasifikasi penutupan lahan dengan teknik ML algoritma RF, CART, SVM. *Kelima*, melakukan uji akurasi dengan membandingkan contoh klasifikasi dan hasil klasifikasi, jika akurasi < 50%, maka pengulangan pengambilan contoh klasifikasi. *Keenam*, analisa deforestasi tahun 2000-2021, berdasarkan hasil analisa diperoleh kesimpulan penelitian ini.

3.2 Diagram Alir Penelitian



Gambar 1. Diagram Alir Penelitian

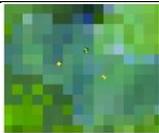
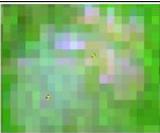
Berdasarkan (Gambar 1) dibagi menjadi beberapa tahap. *Pertama*, dilakukan studi literatur bertujuan menambah wawasan penulis dalam melakukan penelitian. *Kedua*, Pengumpulan citra Landsat-7 perekaman tahun 2000, citra Sentinel-2A perekaman tahun 2021, batas administrasi Kabupaten

3.3 Pengambilan Contoh Klasifikasi

Pengambilan contoh klasifikasi dengan teknik *random sampling* berdasarkan kelas penutupan lahan citra Landsat-7 perekaman tahun 2000 dan Sentinel-2A perekaman tahun 2021. Kelas penutupan lahan (Tabel 1). Parameter spektral klasifikasi menggunakan saluran biru, merah, hijau, infra merah dekat dan gelombang pendek infra merah 1 dan 2.

TABEL 1. KELAS PENUTUPAN LAHAN

No	Citra		Keterangan
	Landsat-7 Tahun 2000	Sentinel-2A Tahun 2021	
1			Hutan alam
2	Tidak ada hutan tanaman		Hutan tanaman
3			Pertanian dan perkebunan
4			Semak/belukar
5			Pemukiman
6			Rawa
7			Tanah terbuka
8			Tubuh air

No	Citra		Keterangan
	Landsat-7 Tahun 2000	Sentinel-2A Tahun 2021	
9			Awan

3.4 Klasifikasi Penutupan lahan Algoritma ML

Klasifikasi penutupan lahan menggunakan tiga algoritma ML yang dijalankan pada *platform cloud computing Google Earth Engine (GEE)*. Deskripsi ketiga algoritma ML (Tabel 2). Algoritma RF menggunakan 5 pohon dan 1 penyekat (*split*), algoritma CART 200 *node* (cabang keputusan) dan 1 penyekat (*split*), dan algoritma SVM sesuai dengan pengaturan GEE (Tabel 2).

TABEL 2. DESKRIPSI ALGORITMA ML

No	Algoritma	Deskripsi algoritma
1	RF	ee.Classifier.smileRandomForest(5, 1, minLeafPopulation, bagFraction, maxNodes, seed)
2	CART	ee.Classifier.smileCart(200,1)
3	SVM	ee.Classifier.libsvm(decisionProcedure, svmType, kernelType, shrinking, degree, gamma, coef0, cost, nu, terminationEpsilon, lossEpsilon, oneClass)

3.1.1 Algoritma RF

Langka-langkah kerja algoritma klasifikasi RF pada gugus data contoh dengan n amatan dan p variabel sebagai berikut [17]:

- g. Melakukan penarikan data contoh acak berukuran n (*bootstrap*)
- h. Membentuk pohon klasifikasi tunggal menggunakan data contoh baru yang terbentuk dari proses *bootstrap*. Pohon klasifikasi dilakukan *random forest selection* dengan pemilihan variabel penjelas secara acak dengan $m < p$. Kemudian m variabel penjelas dipilih peubah terbaik sebagai penyekat dan diteruskan dengan menyekat menjadi dua simpul baru.
- i. Mengulangi Langkah di atas sebanyak k kali sehingga diperoleh k buah pohon klasifikasi. Setiap pohon klasifikasi menghasilkan k buah suara berdasarkan suara terbanyak (*majority vote*)

Ukuran penentuan variabel penting pada RF yaitu *Mean Decrease Gini* (MDG). Perhitungan MDG didefinisikan sebagai berikut [25]:

$$MGD_s = \frac{1}{k} \sum_t [\Delta(s, t) I(s, t)] \quad (1)$$

k menyatakan banyak pohon klasifikasi yang terbentuk, $\Delta(s, t)$ adalah impuritas tereduksi yang disebabkan oleh peubah penjelas ke- s pada simpul ke- t dan $I(s, t)$ adalah fungsi indikator yang bernilai 1 jika peubah penjelas ke- s digunakan dalam penyekatan dan selainnya bernilai 0.

3.1.2 Algoritma CART

CART adalah algoritma non-parametrik yang menghasilkan sebuah pohon keputusan berupa *binary tree*. Pohon keputusan dapat berupa pohon klasifikasi kelas kategori atau pohon regresi kelas numerik [18]

Menurut [18] penyekatan terbaik dipilih berdasarkan ukuran penurunan heterogen suatu simpul atau impuritas tereduksi. Jika semakin besar nilai impuritas tereduksi, maka suatu penyekat dapat memaksimalkan kehomogenan di dalam masing-masing simpul yang terbentuk. [18] Impuritas berupa Indeks Gini didefinisikan sebagai berikut:

$$i(t) = 1 - \sum_{j=0}^1 p^2(j|t) \quad (3)$$

$$p(j|t) = \frac{N_j(t)}{N(t)} \quad (4)$$

dengan $p(j|t)$ adalah peluang amatan kelas k - j pada simpul ke- t , $N_j(t)$ adalah total amatan kelas ke- j pada simpul ke- t , dan $N(t)$ adalah total amatan pada simpul ke- t .

Sedangkan menghitung impuritas tereduksi dari suatu penyekat s didefinisikan sebagai berikut:

$$\Delta i(s, t) = i(t) - p_L i(t_L) - p_R i(t_R) \quad (5)$$

p_L adalah peluang amatan pada simpul kiri, $i(t_L)$ merupakan nilai impuritas pada simpul kiri, p_R adalah peluang amatan pada simpul kanan, $i(t_R)$ adalah nilai impuritas pada simpul kanan.

3.1.3 Algoritma SVM

Algoritma SVM adalah teknik klasifikasi untuk menemukan *hyperplane* di ruang dimensi tinggi yang memisahkan data pelatihan ke dalam kelas sehingga anggota kelas terpisah secara maksimal [20]. *Hyperplane* memaksimalkan margin dimana margin adalah jumlah jarak ke *hyperplane* dari titik terdekat

setiap kelas disebut dengan *support vector*. Pemisahan kelas pada SVM dapat dipisahkan secara sempurna oleh *hyperplane* didefinisikan sebagai berikut [26]:

$$w \cdot x + b \tag{6}$$

dengan w adalah sebuah vektor dimensi- p (dimana p adalah banyak peubah), x sebuah vektor dimensi- p $x = (x_1, x_2, \dots, x_p)$ dan b sebagai bias. Pengklasifikasian x sebagai kelas-1 jika:

$$wx + b \leq -1 \tag{7}$$

dan diklasifikasikan sebagai kelas +1 jika

$$wx + b > 1 \tag{8}$$

Margin maksimal ditemukan dengan mengoptimalkan *hyperplane* yaitu dengan mencari titik minimal dari:

$$\min_{w, \tau} (w) = \frac{1}{2} \|w\|^2 \tag{9}$$

Mencari *hyperplane* optimal dengan formula di atas akan membuat masalah *Quadratic Programming* (QP), masalah ini dapat diselesaikan menggunakan *lagrange multiplier*, yang didefinisikan sebagai berikut:

$$\max_{\alpha} \left(\sum_{i=1}^N \alpha_i - \frac{1}{2} \sum_{i,j=1}^N \alpha_i \alpha_j y_i y_j x_i x_j \right), \tag{10}$$

Subjek $0 \leq \alpha \leq C$ dan $\sum_{i=1}^N \alpha_i y_i = 0$

i adalah pengali *Lagrange*, C adalah parameter yang berfungsi mengontrol optimisasi antara margin dan kesalahan kalsifikasi, semakin besar parameter C , semakin besar pula penalti terhadap kesalahan klasifikasi dan $x_i x_j$ adalah hasil kali titik antara titik $x_i x_j$. Data penginderaan jauh non linier, oleh karena itu data harus dipetakan melalui fungsi kernel yang umum digunakan kernel *Radial Basis Function* (RBF) didefinisikan sebagai berikut [27]:

$$(k(x_i, x_j) = \exp(-(x_i - x_j)^2 / -2\sigma^2) \tag{11}$$

dengan k adalah fungsi kernel, dan σ adalah panjang gelombang saluran.

3.2 Uji Akurasi

Kebenaran klasifikasi menggunakan teknik matrik konfusi [28]. Uji akurasi membandingkan hasil

klasifikasi dengan data contoh klasifikasi berdasarkan (Tabel 3).

TABEL 3. Matrik Konfusi

Data Referensi	Diklasifikasikan ke kelas		Jumlah	Akurasi Pembuat
	A	B		
A	X ₁₁	X ₁₂	X ₁₊	X ₁₁ /X ₁₊
B	X ₂₁	X ₂₂	X ₂₊	X ₂₂ /X ₂₊
Jumlah	X ₊₁	X ₊₂		
Akurasi Pengguna	X ₁₁ /X ₊₁	X ₂₂ /X ₊₁		

Berikut rumus yang digunakan untuk mengukur uji akurasi *Overall Accuracy* (OA) dan *Kappa Accuracy* (KA):

$$\text{Overall Accuracy (OA)} = \frac{\sum_{i=1}^r X_{ii}}{N} 100\% \tag{12}$$

$$\text{Kappa Accuracy (KA)} = \frac{N \sum_{i=1}^r X_{ii} - \sum_{i=1}^r X_{i+} X_{+i}}{N^2 - \sum_{i=1}^r X_{i+} X_{+i}} 100\% \tag{13}$$

dimana X_{ii} adalah nilai diagonal dari matrik kontingensi baris ke- i dan kolom ke- i , X_{+i} adalah jumlah luas m^2 dalam kolom ke- i , X_{i+} adalah jumlah luas m^2 dalam baris ke- i , dan N adalah jumlah luas m^2 X_{+i} dan X_{i+} .

3.5 Analisis Laju Deforestasi

Analisis laju deforestasi merupakan analisis menunjukkan kecepatan deforestasi dalam satuan ha/waktu atau persentase/ha, rumus yang digunakan sebagai berikut [29]:

$$\text{laju deforestasi} = \frac{lh_d}{t} \tag{3}$$

$$\text{persentase deforestasi} = \frac{lh_d/lh}{t} * 100 \tag{4}$$

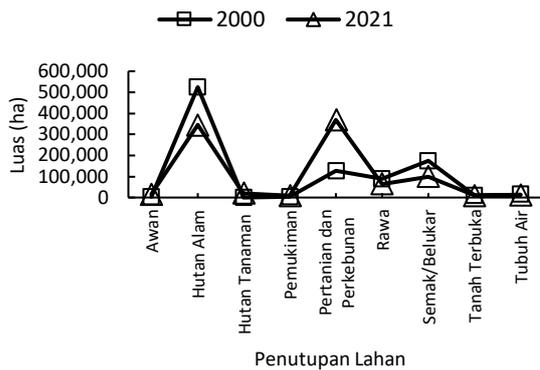
dimana Lhd adalah luas hutan yang mengalami deforestasi per periode waktu, Lh adalah luas hutan keseluruhan, dan t adalah lamanya periode waktu.

4. HASIL DAN PEMBAHASAN

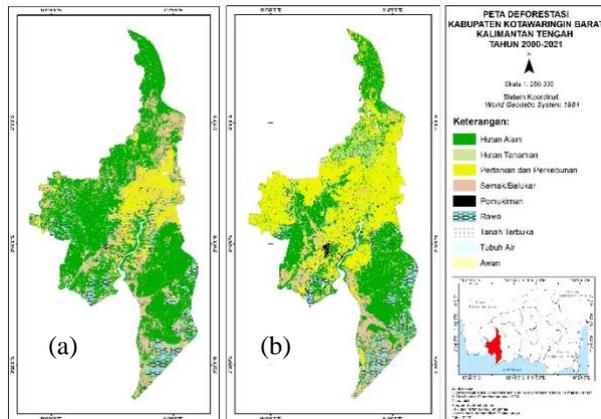
4.1 Identifikasi Penutupan Lahan dan Laju Deforestasi

Hasil penelitian ini menunjukkan bahwa penutupan hutan alam mengalami penurunan seluas 180.073 ha yang terjadi antara tahun 2000 hingga 2021, sedangkan penutupan pertanian dan perkebunan menunjukkan peningkatan seluas 242.584 ha pada tahun 2000 hingga 2021 (Gambar 2). Sebaran spasial penutupan lahan menunjukkan bahwa terdapat

perubahan penutupan lahan hutan alam warna hijau tua menjadi pertanian dan perkebunan warna kuning pada arah barat dan barat laut dan utara dan timur laut (Gambar 3). Hasil penelitian ini sejalan dengan [30] yang menyatakan bahwa ekspansi perkebunan kelapa sawit salah penyebab faktor deforestasi yang terjadi di Kalimantan. Pertumbuhan ekonomi Kabupaten Kotawaringin barat penyumbang utamanya sektor pertanian khususnya perkebunan kelapa sawit selama periode 2008-2013 [31].



Gambar 2. Kondisi penutupan lahan tahun 2000-2021

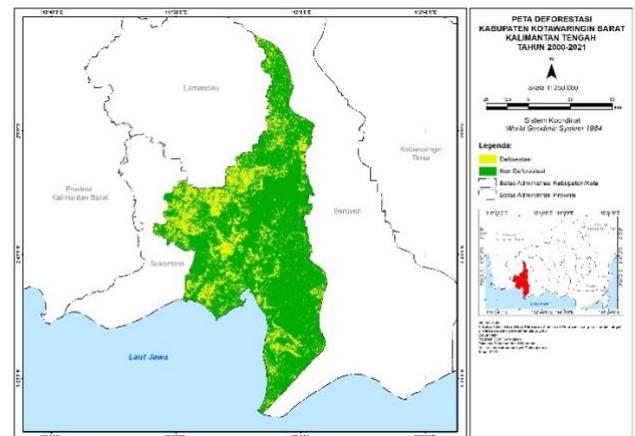


Gambar 3. Sebaran spasial penutupan lahan tahun 2000 (a) dan penutupan lahan tahun 2021 (b)

Laju deforestasi seluas 24.975 ha/th atau 1.9 %/th selama 21 tahun atau periode tahun 2000-2021 dan luas deforestasi 214.990 ha/periode (Tabel 4). Sebaran spasial area yang mengalami deforestasi (Gambar 4) warna hijau area yang tidak mengalami deforestasi dan warna kuning area yang mengalami deforestasi. Konversi hutan alam menjadi pertanian dan perkebunan setara 30% di Kabupaten Kotawaringin Barat [32]. [33] menyatakan bahwa hutan rawa gambut (hutan alam) telah dikonversi menjadi perkebunan kelapa sawit pada awal tahun 2000-an yang menyebabkan hilangnya keanekaragaman hayati di Kalimantan.

TABEL 4. ANALISIS LAJU DEFORESTASI

Keterangan	Analisis
Luas hutan (ha)	524.471
Periode deforestasi	2000-2021
Lama periode	21
Laju deforestasi (ha/th)	24.975
Laju deforestasi (%/ha)	1.9
Luas deforestasi (ha/periode)	214.990
Luas hutan tanpa deforestasi (ha/periode)	728.887



Gambar 4. Lintasan deforestasi tahun 2000-2021 di Kabupaten Kotawaringin Barat

4.2 Komparasi ML Algoritma

Penelitian ini menunjukkan bahwa secara konsisten algoritma RF dengan akurasi rerata OA 95% dan Kappa 94%, kemudian disusul algoritma CART rerata OA 80% dan Kappa 84%, dan algoritma SVM rerata OA 74% dan Kappa 66% (Tabel 5). Hasil penelitian ini sejalan dengan [21] menggunakan algoritma RF akurasi yang dihasilkan Kappa 91%-94% memantau hutan hujan tropis di Amazon. Penelitian lainnya algoritma RF menunjukkan akurasi kappa 92% memetakan dampak penebang selektif hutan hujan tropis Brasil [34]. Algoritma RF menghasilkan akurasi yang baik, hal ini dipengaruhi salah satunya faktor data input saluran yang berbeda sehingga meningkatkan karakterisasi penutupan lahan, dengan menumbuhkan pohon keputusan yang kemudian penentuan kelas (a) berdasarkan suara terbanyak [35]. Algoritma CART hanya mengembangkan pohon keputusan biner (0) salah dan (1) benar [18]. Sementara itu algoritma SVM merupakan klasifikasi dan regresi, kunci dari keberhasilan algoritma ini menemukan *hyperplane* pemisah antar kelas [20], [36]. Penelitian [37] menyatakan algoritma SVM menghasilkan akurasi 65%

untuk klasifikasi jenis dan tingkat kematangan buah pepaya.

TABEL 5. KOMPARASI ML ALGORITMA

Algoritma ML	Akurasi (%)					
	2000		2021		Rerata	
	OA	Kappa	OA	Kappa	OA	Kappa
RF	95	94	95	94	95	94
CART	90	88	84	80	87	84
SVM	74	66	73	65	74	66

5. KESIMPULAN DAN SARAN

Hasil penelitian ini menunjukkan bahwa penutupan hutan alam mengalami penurunan seluas 180.073 ha terjadi antara tahun 2000 hingga 2021, sedangkan penutupan pertanian dan perkebunan menunjukkan peningkatan luasan seluas 242.584 ha pada tahun 2000 hingga 2021. Laju deforestasi 24.975 ha/th atau 1.9%/th. Algoritma RF menunjukkan hasil yang terbaik untuk deteksi deforestasi dengan rerata akurasi OA 95% dan Kappa 94%.

Penelitian selanjutnya perlu menguji konsistensi algoritma ML khususnya RF berdasarkan tipe ekosistem hutan menggunakan citra resolusi spasial menengah Landsat, Sentinel dan citra resolusi spasial tinggi SPOT dan Pleiades.

UCAPAN TERIMA KASIH

Ucapan terima kasih kepada Lembaga Penelitian dan Pengabdian Kepada Masyarakat (LP2M) Universitas Muhammadiyah Palangkaraya (UMPR) sebagai sumber pendanaan penelitian ini, Fakultas Kehutanan dan Pertanian, Program Studi Kehutanan UMPR. Selain itu juga, terima kasih kepada penelaah artikel ini sehingga jurnal ini menjadi lebih baik.

DAFTAR PUSTAKA

- [1] K. G. Austin, A. Schwantes, Y. Gu, and P. S. Kasibhatla, "What causes deforestation in Indonesia?," *Environ. Res. Lett.*, vol. 14, no. 2, p. 24007, 2019.
- [2] D. L. A. Gaveau *et al.*, "Rapid conversions and avoided deforestation: examining four decades of industrial plantation expansion in Borneo," *Sci. Rep.*, vol. 6, no. 1, pp. 1–13, 2016.
- [3] D. L. A. Gaveau *et al.*, "Four decades of forest persistence, clearance and logging on Borneo," *PLoS One*, vol. 9, no. 7, p. e101654, 2014.
- [4] L. P. Koh, J. Miettinen, S. C. Liew, and J. Ghazoul, "Remotely sensed evidence of tropical peatland conversion to oil palm," *Proc. Natl. Acad. Sci.*, vol. 108, no. 12, pp. 5127–5132, 2011.
- [5] B. A. Margono, P. V. Potapov, S. Turubanova, F. Stolle, and M. C. Hansen, "Primary forest cover loss in Indonesia over 2000–2012," *Nat. Clim. Chang.*, vol. 4, no. 8, pp. 730–735, 2014.
- [6] L. S. Wijedasa, S. Sloan, S. E. Page, G. R. Clements, M. Lupascu, and T. A. Evans, "Carbon emissions from South-East Asian peatlands will increase despite emission-reduction schemes," *Glob. Chang. Biol.*, vol. 24, no. 10, pp. 4598–4613, 2018.
- [7] Z. Chen and J. Wang, "Land use and land cover change detection using satellite remote sensing techniques in the mountainous Three Gorges Area, China," *Int. J. Remote Sens.*, vol. 31, no. 6, pp. 1519–1542, 2010.
- [8] A. Krasovskii, V. Maus, P. Yowargana, S. Pietsch, and M. Rautiainen, "Monitoring deforestation in rainforests using satellite data: A pilot study from Kalimantan, Indonesia," *Forests*, vol. 9, no. 7, p. 389, 2018.
- [9] D. P. Roy *et al.*, "Landsat-8: Science and product vision for terrestrial global change research," *Remote Sens. Environ.*, vol. 145, pp. 154–172, 2014.
- [10] S. Talukdar, P. Singha, S. Mahato, S. Pal, Y.-A. Liou, and A. Rahman, "Land-use land-cover classification by machine learning classifiers for satellite observations—A review," *Remote Sens.*, vol. 12, no. 7, p. 1135, 2020.
- [11] D. Apriyanto, I. N. Jaya, and N. Puspaningsih, "Examining the object-based and pixel-based image analyses for developing stand volume estimator model," *Indones. J. Electr. Eng. Comput. Sci.*, vol. 15, p. 1586, Sep. 2019, doi: 10.11591/ijeecs.v15.i3.pp1586-1596.
- [12] Y. H. Tsai, D. Stow, H. L. Chen, R. Lewison, L. An, and L. Shi, "Mapping vegetation and land use types in Fanjingshan National Nature Reserve using google earth engine," *Remote Sens.*, vol. 10, no. 6, p. 927, 2018.
- [13] V. F. Rodriguez-Galiano, B. Ghimire, J. Rogan, M. Chica-Olmo, and J. P. Rigol-Sanchez, "An assessment of the effectiveness of a random forest classifier for land-cover classification," *ISPRS J. Photogramm. Remote Sens.*, vol. 67, pp. 93–104, 2012.
- [14] N. S. N. Shahrurum, H. Z. M. Shafri, W. A. W. A. K. Ghani, S. Samsatli, M. M. A. Al-Habshi, and B. Yusuf, "Oil palm mapping over Peninsular Malaysia using Google Earth Engine and machine learning algorithms," *Remote Sens. Appl. Soc. Environ.*, vol. 17, p. 100287, 2020.
- [15] S. Bar, B. R. Parida, and A. C. Pandey, "Landsat-8 and Sentinel-2 based Forest fire burn area mapping using machine learning algorithms on GEE cloud platform over Uttarakhand, Western Himalaya," *Remote Sens. Appl. Soc. Environ.*, vol. 18, p. 100324, 2020.

- [16] A. M. Abdi, "Land cover and land use classification performance of machine learning algorithms in a boreal landscape using Sentinel-2 data," *GIScience Remote Sens.*, vol. 57, no. 1, pp. 1–20, 2020.
- [17] L. Breiman, "Random forests," *Mach. Learn.*, vol. 45, no. 1, pp. 5–32, 2001.
- [18] L. Breiman, J. Friedman, R. A. Olshen, and C. J. Stone, "Classification and regression trees. Brooks," *Wadsworth Brooks, Monterey, CA*, 1984.
- [19] Y. Shao and R. S. Lunetta, "Comparison of support vector machine, neural network, and CART algorithms for the land-cover classification using limited training data points," *ISPRS J. Photogramm. Remote Sens.*, vol. 70, pp. 78–87, 2012.
- [20] V. Vapnik, *The nature of statistical learning theory*. Springer science & business media, 1999.
- [21] M. A. Brovelli, Y. Sun, and V. Yordanov, "Monitoring forest change in the amazon using multi-temporal remote sensing data and machine learning classification on Google Earth Engine," *ISPRS Int. J. Geo-Information*, vol. 9, no. 10, p. 580, 2020.
- [22] A. S. Fikri, F. Setiawan, W. A. Violando, A. D. Muttaqin, and F. Rahmawan, "Analisis Perubahan Penutupan Lahan Menggunakan Google Earth Engine dengan Algoritma Cart (Studi Kasus: Wilayah Pesisir Kabupaten Lamongan, Provinsi Jawa Timur)," in *Prosiding Forum Ilmiah Tahunan (FIT)-Ikatan Surveyor Indonesia (ISI)*, 2021, vol. 1, pp. 89–99.
- [23] N. Farda, "Multi-temporal Land Use Mapping of Coastal Wetlands Area using Machine Learning in Google Earth Engine," *IOP Conf. Ser. Earth Environ. Sci.*, vol. 98, p. 12042, Dec. 2017, doi: 10.1088/1755-1315/98/1/012042.
- [24] A. Dawod and M. A. Sharafuddin, "Assessing mangrove deforestation using pixel-based image: a machine learning approach," *Bull. Electr. Eng. Informatics*, vol. 10, pp. 3178–3190, Dec. 2021, doi: 10.11591/eei.v10i6.3199.
- [25] S. Zani, M. Riani, and M. Vichi, *Data analysis, classification and the forward search: proceedings of the Meeting of the Classification and Data Analysis Group (CLADAG) of the Italian Statistical Society, University of Parma, June 6-8, 2005*. Springer Science & Business Media, 2006.
- [26] Y. Sun, A. K. C. Wong, and M. S. Kamel, "Classification of imbalanced data: A review," *Int. J. pattern Recognit. Artif. Intell.*, vol. 23, no. 04, pp. 687–719, 2009.
- [27] A. Zafari, R. Zurita-Milla, and E. Izquierdo-Verdiguier, "Evaluating the performance of a random forest kernel for land cover classification," *Remote Sens.*, vol. 11, no. 5, p. 575, 2019.
- [28] G. H. Rosenfield and K. Fitzpatrick-Lins, "A coefficient of agreement as a measure of thematic classification accuracy," *Photogramm. Eng. Remote Sensing*, vol. 52, no. 2, pp. 223–227, 1986.
- [29] P. I. P. Sari, "Penyusunan Baseline Deforetasi Berbasis Spasial di Beberapa Kecamatan Provinsi Jambi," 2014.
- [30] A. S. Alisjahbana and J. M. Busch, "Forestry, Forest Fires, and Climate Change in Indonesia," *Bull. Indones. Econ. Stud.*, vol. 53, no. 2, pp. 111–136, May 2017, doi: 10.1080/00074918.2017.1365404.
- [31] B. P. S. K. Barat, S. I. Pengolahan, D. Statistik, and G. Kulit, "Kotawaringin Barat Dalam Angka 2013," *Pangkalan Bun*, 2013.
- [32] S. Irawan, T. Widiastomo, L. Tacconi, J. Watts, and B. Steni, "Exploring the design of jurisdictional REDD+: The case of Central Kalimantan, Indonesia," *For. Policy Econ.*, vol. 108, Nov. 2019, doi: 10.1016/j.forpol.2018.12.009.
- [33] K. L. Pin, M. Jukka, L. S. Chin, and G. Jaboury, "Remotely sensed evidence of tropical peatland conversion to oil palm," *Proc. Natl. Acad. Sci.*, vol. 108, no. 12, pp. 5127–5132, Mar. 2011, doi: 10.1073/pnas.1018776108.
- [34] M. G. Hethcoat, D. P. Edwards, J. M. B. Carreiras, R. G. Bryant, F. M. França, and S. Quegan, "A machine learning approach to map tropical selective logging," *Remote Sens. Environ.*, vol. 221, pp. 569–582, 2019, doi: <https://doi.org/10.1016/j.rse.2018.11.044>.
- [35] C. Pelletier, S. Valero, J. Inglada, N. Champion, and G. Dedieu, "Assessing the robustness of Random Forests to map land cover with high resolution satellite image time series over large areas," *Remote Sens. Environ.*, vol. 187, pp. 156–168, 2016, doi: <https://doi.org/10.1016/j.rse.2016.10.010>.
- [36] D. Srivastava and L. Bhambhu, "Data classification using support vector machine," *J. Theor. Appl. Inf. Technol.*, vol. 12, pp. 1–7, Feb. 2010.
- [37] L. A. Wardani, "Klasifikasi Jenis Dan Tingkat Kematangan Buah Pepaya Berdasarkan Fitur Warna, Tekstur Dan Bentuk Menggunakan Support Vector Machine," *Publ. Tugas Akhir S-1 PSTI FT-UNRAM*, 2020.