

Identifikasi Area Terdampak *Oil Seep* di Darat dari Data Foto Udara Menggunakan Metode *Object Based Image Analysis* dan *Convolutional Neural Networks* (Studi Kasus: Kelurahan "X")

Nurul Fitri Alya, Filsa Bioresita, Noorlaila Hayati, Muhammad Alfian Romadhon,
dan Sony Hardian Meisajiwa
Departemen Teknik Geomatika, Institut Teknologi Sepuluh Nopember (ITS)
e-mail: noorlaila@geodesy.its.ac.id

Abstrak—Rembesan minyak merupakan salah satu peristiwa yang merugikan lingkungan pada industri minyak dan gas. Hal ini dikarenakan senyawa kimia yang terkandung pada rembesan minyak dapat mengakibatkan penurunan kualitas lingkungan hidup. Rembesan minyak (*Oil Seep*) tidak hanya terjadi di wilayah perairan, tetapi juga di daratan, yang terserap oleh tanah. Kejadian ini dapat mengindikasikan adanya sistem perminyakan di bawah permukaan tanah. Dalam penelitian ini daerah terdampak rembesan minyak diidentifikasi menggunakan metode *deep learning* dengan *Convolutional Neural Networks* dimana mesin diharapkan meniru sistem kerja otak manusia dalam mengidentifikasi objek. Data foto udara yang telah terorthorektifikasi dilakukan proses segmentasi untuk membantu proses pelabelan *training data* pada tahap selanjutnya. *Training data* tersebut menjadi data masukan pada tahap *train deep learning model*, dan akan dilakukan proses klasifikasi piksel untuk mendeteksi area terdampak *oil seep*. Hasil pengolahan berupa tingkat akurasi model mencapai 93% dan raster yang menampilkan area terdampak *oil seep*, yang kemudian dihitung luasan areanya, dan menghasilkan perhitungan area terdampak *oil seep* seluas $\pm 1,4$ hektar.

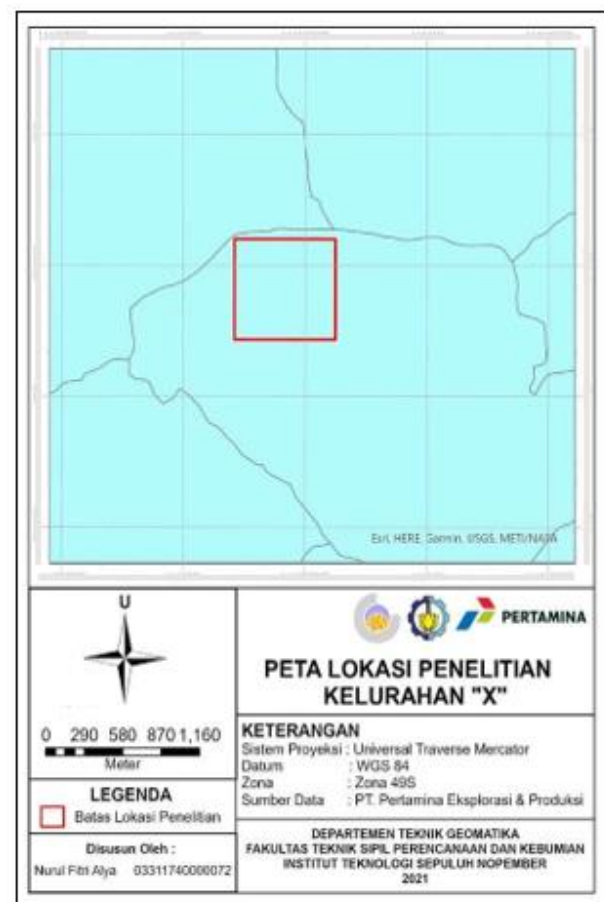
Kata Kunci—*Oil Seep*, Rembesan Minyak, *Deep Learning*, *Convolutional Neural Networks*, Pembobotan, Area Terdampak Rembesan Minyak.

I. PENDAHULUAN

INDUSTRI minyak dan gas telah menjadi salah satu sumber pendapatan utama negara, yang meliputi proses eksplorasi dan eksploitasi. Namun, pelaksanaan proses ini juga memberikan dampak buruk bagi lingkungan, misalnya pengilangan minyak bumi, kecelakaan transportasi, dan kebocoran pipa yang dapat mengakibatkan penurunan kualitas lingkungan hidup [1].

Rembesan minyak tidak hanya terjadi di wilayah perairan, namun juga di daratan, yang terserap tanah. Contoh kasus rembesan minyak yang sering terjadi yakni pada wilayah pantai California dan teluk Meksiko. Di Indonesia, kasus rembesan minyak terjadi di Prabumulih, Sumatera Selatan yang mengalir hingga ke Kebun Warga.

Kasus lain rembesan minyak di darat terjadi di wilayah yang disamakan, yang merupakan wilayah kontrak minyak dan gas bumi. Di wilayah ini, banyak terdapat sumur tua hasil eksploitasi perusahaan konsesi minyak dari Hindia Belanda sejak tahun 1894. Sumur-sumur tua tersebut dikelola oleh instansi, tetapi beberapa sumur masih dikelola oleh masyarakat setempat. Namun, pada praktiknya, kegiatan eksplorasi dan eksploitasi minyak bumi ini belum

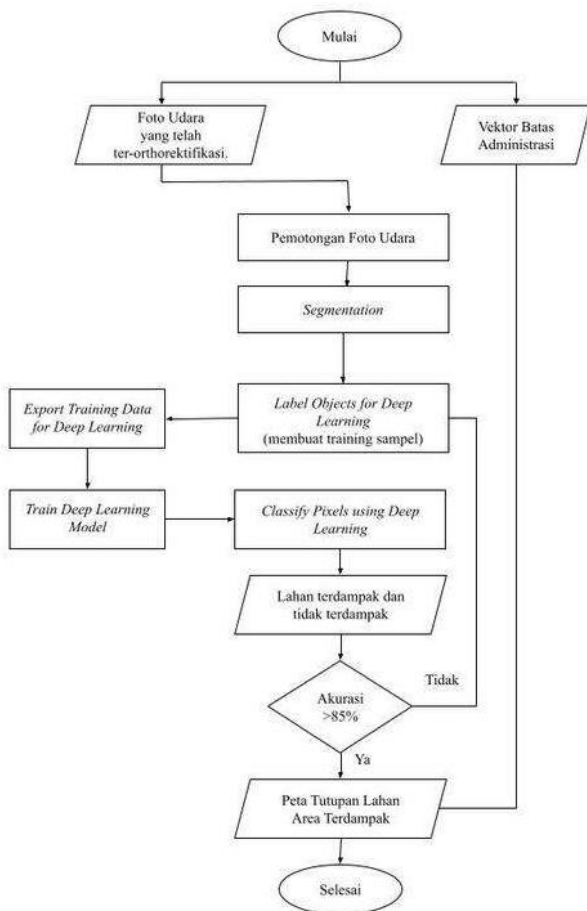


Gambar 1. Peta Lokasi Penelitian.

memperhatikan peraturan AMDAL dan merupakan kegiatan illegal [2].

Pemantauan area terdampak secara langsung di lapangan dapat menimbulkan berbagai resiko, mulai dari kontak langsung dengan minyak, bahaya lokasi, hingga konflik masyarakat [3]. Sehingga, peneliti menganggap perlu dilakukan pemetaan area terdampak *oil seep*, salah satunya dengan memanfaatkan data foto udara tanpa kontak langsung di lapangan. Tampilan rembesan minyak pada foto berwarna hitam dan tersebar, hal ini dikarenakan minyak yang muncul ke permukaan tanah akan berubah dari cairan menjadi zat seperti tar karena unsur minyak yang lebih ringan menguap, dan meninggalkan senyawa minyak yang lebih berat kemudian teroksidasi oleh udara dan bakteri.

Foto udara bermanfaat dalam mengidentifikasi tutupan lahan di sekitar area pertambangan, karena memiliki resolusi



Gambar 2. Diagram Alir Pengolahan Data.

spasial yang tinggi hingga satuan *centimeter* [4]. Sehingga, area terdampak *oil seeps* dapat diidentifikasi. Salah satu metode yang dapat digunakan untuk mengidentifikasi area terdampak *oil seeps* yaitu dengan memanfaatkan *Deep Learning*, khususnya teknik *Convolutional Neural Networks (CNN)* yang meniru sistem pengenalan citra pada visual korteks manusia sehingga memiliki kemampuan mengolah informasi citra [5]. Beberapa penelitian juga menerapkan metode *Object Based Image Analysis* untuk menaikkan tingkat akurasi, seperti penelitian yang dilakukan dengan menerapkan metode OBIA dan CNN untuk klasifikasi tutupan lahan, yang mendapatkan peningkatan akurasi dari 90,6% menjadi 93,2% [6].

Penelitian ini bermaksud untuk mendeteksi area terdampak *oil seep* dari data foto udara menggunakan metode OBIA dan CNN.


II. METODE PENELITIAN

A. Lokasi Penelitian

Lokasi penelitian disamarkan untuk menjaga kerahasiaan data instansi terkait, yang merupakan wilayah kontak minyak dan gas. Di lokasi ini, banyak terdapat sumur tua sejak jaman Hindia Belanda yang sampai sekarang beberapa diantaranya masih dikelola oleh masyarakat setempat. Luas lokasi penelitian seluas ± 84 hektar. Gambaran wilayah penelitian disajikan pada Gambar 1.

B. Data dan Peralatan

Adapun data yang diperlukan dalam penelitian ini adalah sebagai berikut:



Gambar 3. Pelabelan objek.



Gambar 4. Pelabelan objek tiap kelas (biru; area tidak terdampak, dan merah; area terdampak).


1. Data Foto Udara yang telah terorthorektifikasi dengan akuisisi data tahun 2015 dengan resolusi spasial 8cm.
2. Vektor Batas Penelitian

C. Peralatan

Peralatan yang digunakan pada penelitian ini meliputi perangkat keras dan perangkat lunak. Perangkat keras yang digunakan adalah komputer. Perangkat lunak yang digunakan untuk pengolahan *deep learning* adalah aplikasi pengolahan citra dan ArcGIS Pro 2.7, dan perangkat lunak pengolah kata dan angka yakni Microsoft Office.

D. Pengolahan Data

Pengolahan data pada penelitian ini secara garis besar



Gambar 5. Image chips.

berupa pembuatan *training data*, *training model*, dan klasifikasi piksel. Adapun detail pengolahan tersebut ditunjukkan oleh diagram alir yang ada pada Gambar 2.

1) Pemotongan Foto Udara

Pemotongan foto udara dilakukan di awal sesuai batas lokasi penelitian agar mempermudah dalam pengolahan data.

2) Segmentasi

Segmentasi merupakan tahap pada metode OBIA, yakni proses yang membagi foto menjadi beberapa segmen sesuai karakteristik masing-masing piksel. Beberapa parameter pada segmentasi yang perlu diatur antara lain *spectral detail* (parameter untuk memberikan perbedaan fitur spectral pada foto), *spatial detail* (parameter untuk membedakan fitur pada foto), dan *minimum segment size*. Parameter-parameter tersebut diatur dengan nilai sebagai berikut, antara lain:

a) *Spectral Detail*: 20

b) *Spatial Detail*: 17

c) *Minimum Segment Size in Pixels*: 10

E. Pelabelan Training Sampel

Pembuatan label pada foto dilakukan sebagai *input* data pada proses *deep learning*. Pelabelan objek dilakukan dari hasil segmentasi dan terbagi menjadi 2 kelas, yakni kelas area terdampak dan tidak terdampak. Sampel area terdampak dibuat sebanyak 1700 sampel, sedangkan area tidak terdampak sebanyak 260 titik. Penentuan jumlah sampel berdasarkan kenampakan di foto, cukup tersebar rata pada semua bagian foto udara, seperti yang terlihat pada Gambar 3 dan Gambar 4.

F. Export Label

Export label dilakukan untuk merubah format label objek menjadi format *training data* untuk proses *deep learning*. Proses *export label* ini menghasilkan luaran berupa *image chips* sebanyak 15,843 potongan citra seperti pada Gambar 5.

Image chips didapat dari pelabelan objek dan menjadikannya menjadi potongan-potongan citra yang dilakukan pergeseran/translasi maupun perputaran/rotasi untuk mendapatkan lebih banyak informasi dari pelabelan objek.



Gambar 6. Hasil Segmentasi.

G. Train Model

Hasil *export* label akan menjadi data masukan pada proses *Train Model*. Pada proses *train deep learning model* di ArcGIS Pro, terdapat beberapa parameter yang perlu diatur pada saat proses *train deep learning* ini, antara lain:

1. *Max epochs* (parameter yang mengatur berapa kali dataset akan dilakukan *forward-pass* dan *backward* dalam *neural networks*): 10
2. *Model Type*: U-Net Classification
3. *Batch Size* (jumlah *training sampel* yang akan diproses untuk peatihan dalam satu waktu): 8
4. *Backbone Model*: Resnet-34
5. *Validation*: 20%

Nilai parameter-parameter ini didapatkan dari proses *trial-error* untuk mendapatkan nilai yang tepat untuk diterapkan pada data. Namun, untuk angka validasi sebesar 20%, menandakan bahwa 20% dari data akan disisakan untuk dijadikan data validasi.

H. Klasifikasi Piksel

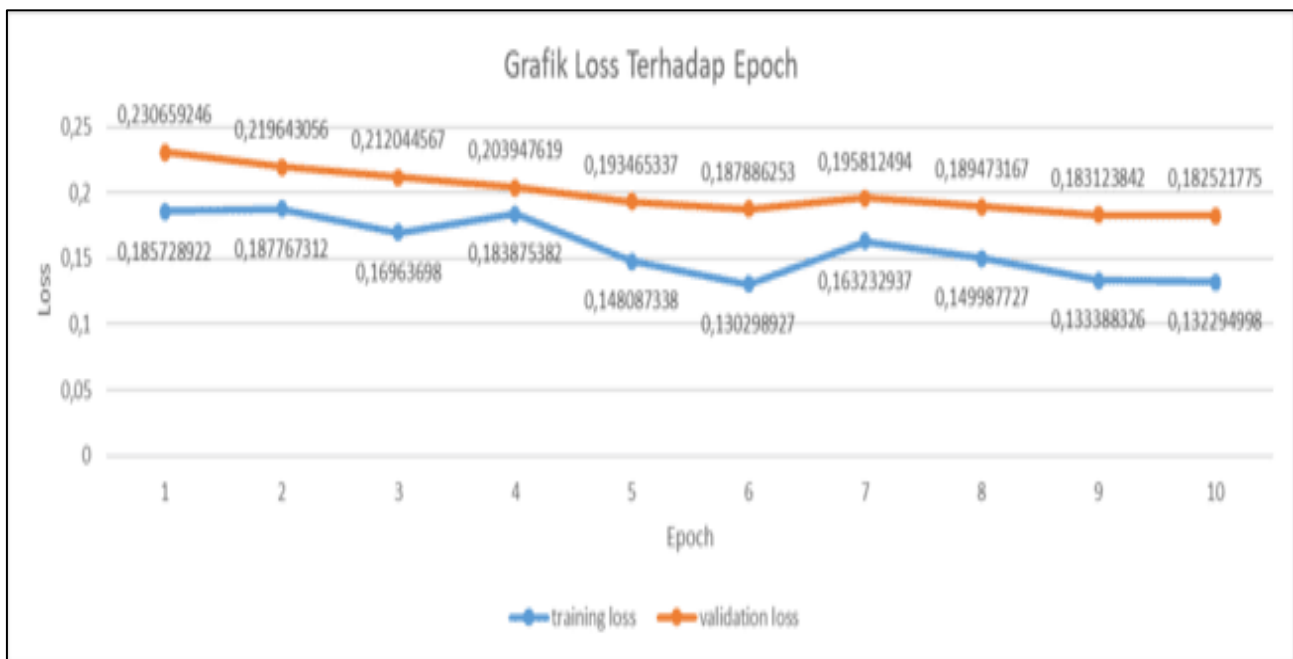
Klasifikasi piksel dilakukan untuk mengklasifikasi tiap piksel pada foto untuk mengidentifikasi tutupan lahan area terdampaknya. Luaran dari *train model* akan selanjutnya dilakukan proses klasifikasi piksel. Pada tahap ini, parameternya antara lain:

1. *Padding* (penambahan ukuran piksel dengan nilai tertentu disekitar data input agar hasil dari bidang *receptive* tidak terlalu kecil sehingga tidak banyak informasi yang hilang).
2. *Batch Size* (ukuran banyak data yang dimasukkan ke proses pelatihan dalam satu iterasi).

Kedua parameter ini diatur tingkatannya sesuai karakteristik data yang digunakan, yang melalui proses *trial-error* untuk mendapatkan nilai yang sesuai. Pada penelitian ini, nilai *padding* sebesar 64, dan *batch size* sebesar 8.

I. Analisa Area Terdampak

Hasil klasifikasi kemudian tampilkan dengan foto udara



Gambar 7. Grafik *loss* terhadap jumlah *epoch*.

sehingga presentase luas area terdampak dapat dilakukan. Perhitungan luas dilakukan dengan *export* data hasil klasifikasi piksel dari raster ke poligon, dan menghitung luasan total poligon yang terdeteksi.

Pembuatan *layout* peta tutupan lahan area terdampak dan yang ditampilkan dengan foto udara dan dibuat sesuai kaidah kartografi.

III. HASIL DAN ANALISA

A. Segmentasi

Pada tahap segmentasi foto, foto dibagi menjadi beberapa segmen dengan pengaturan parameter tertentu, seperti *spectral detail*, *spatial detail*, dan *minimum size in pixel*.

Ketiga parameter ini diterapkan sesuai karakteristik data yang digunakan, misalnya pada *spectral detail* diatur tingkatnya di angka maksimal, yakni 20 agar foto udara terbagi menjadi segmen-segmen yang lebih kecil untuk menghasilkan segmentasi lebih detil. Nilai *spatial detail* juga diatur tinggi dengan nilai 17, untuk membedakan fitur yang mirip seperti lahan kosong dan jalan seperti yang ditunjukkan Gambar 6.

Hasil segmentasi cukup baik untuk dijadikan sebagai data masukan. Hal ini dapat dilihat di Gambar 3 dan Gambar 4, yang menunjukkan segmen terklasifikasi dengan baik sesuai batas tutupan lahan area terdampak dan tidak terdampak.

B. Pelabelan Training Sampel

Pelabelan *training sampel* dalam penelitian ini dilakukan pelabelan objek area terdampak seperti pada Gambar 4. Sampel kemudian diexport ke dalam format *training data* pada proses *deep learning* dengan ukuran sampel 256×256 piksel sebanyak 1700 sampel.

Tahap selanjutnya yakni merubah format *training sampel* tersebut menjadi format *training data* untuk *deep learning*. Pada proses ini, mesin memodifikasi *training sampel* dengan melakukan translasi, rotasi, dan pemotongan ke ukuran lebih kecil untuk memperoleh lebih banyak informasi untuk dipelajari.

C. Train Model

Proses *train model* membutuhkan waktu 22 jam 10 menit. Waktu ini dipengaruhi oleh berbagai faktor, seperti ukuran data, pengaturan parameter, spesifikasi komputer dan sebagainya. Pada penelitian ini, penetapan *epoch* di angka 10 melalui tahap *trial-error*.

Hasil *train model* berupa *deep learning package* dan akurasi yang didapat dari rerata akurasi per *epoch*, didapatkan sebesar 93%. Gambar 7 merupakan grafik yang menunjukkan tingkat optimalisasi *epoch* terhadap data *training* dan data validasi.

Grafik menunjukkan nilai *loss* pada data *training* dan data validasi terhadap *epoch*. Pada grafik, terdapat perbedaan nilai *loss* antara data *training* dan data validasi, serta pengaruh jumlah *epoch* pada proses pelatihan model. Pada grafik tersebut, *epoch* 6 dianggap *epoch* yang paling optimum untuk melatih model terhadap data, karena menunjukkan tingkat *loss* yang rendah sebelum terjadi kenaikan *loss* pada *epoch* ke 7.

Hasil dari *train model* ini akan menjadi data masukan pada tahap selanjutnya, yaitu proses klasifikasi piksel.

D. Klasifikasi Piksel

Proses klasifikasi piksel membutuhkan waktu selama 1 jam 26 menit. Lama proses ini juga dipengaruhi oleh parameter klasifikasi seperti *padding*, *batch size*, serta spesifikasi komputer, dan sebagainya. Klasifikasi piksel menghasilkan tampilan pendeteksian berupa raster. Gambar 8 menunjukkan hasil klasifikasi piksel untuk pendeteksian *oil seep* di darat dengan area terdampak direpresentasikan dengan poligon merah.

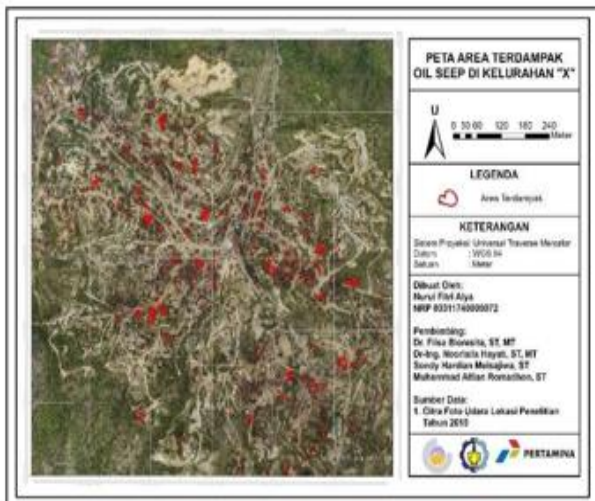
E. Analisa Area Terdampak

Dengan total jumlah poligon area terdampak yang terdeteksi sebanyak 10100 poligon, total luas area terdampak seluas $13,953.0702 \text{ m}^2$ atau 1,4 hektar.

Dari hasil tersebut, peta area terdampak disusun Peta disusun dari data hasil terklasifikasi dengan metode *deep*



Gambar 8. Hasil Klasifikasi Pikel.



Gambar 9. Peta Area Terdampak Oil Seep.

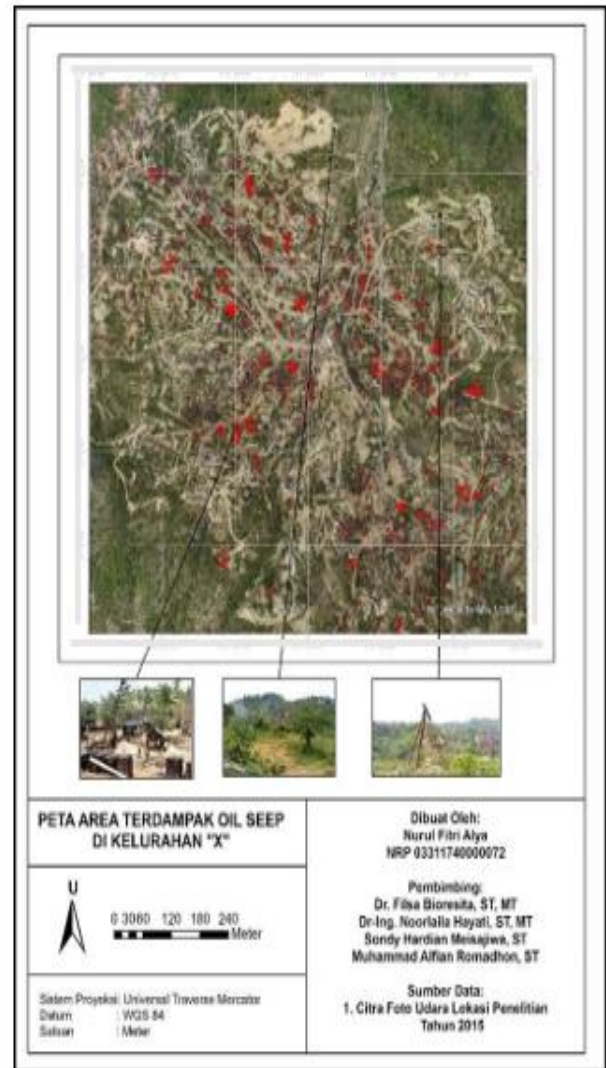
learning dan ditampilkan dengan foto udara dan disusun sesuai kaidah kartografi seperti yang ditunjukkan Gambar 9.

Area terdampak rembesan minyak cenderung memiliki karakteristik tutupan lahan yang kering, namun terdapat vegetasi di sekitar sumur-sumur tersebut. Lokasi penelitian pun tidak memiliki lahan pemukiman karena termasuk wilayah kontrak minyak dan gas dan dikelola oleh instansi terkait, seperti pada Gambar 10.

IV. KESIMPULAN DAN SARAN

A. Kesimpulan

Dari hasil analisis penelitian yang dilakukan dapat diambil kesimpulan yaitu: (1) Proses pendeteksian area terdampak oil seep di darat dengan metode *object based image analysis* dan *deep learning* jenis *convolutional neural networks* yang terdiri dari proses segmentasi pada foto udara, yang kemudian hasilnya digunakan sebagai pembuatan label *training* sampel. *Training* sampel selanjutnya digunakan sebagai data masukan untuk melakukan pelatihan model *deep learning* dengan mengatur beberapa parameter seperti *epoch*, *batch size*, dan



Gambar 10. Peta Keterangan Area Terdampak Oil Seep.

sebagainya. Selanjutnya hasil luaran dari pelatihan model berupa *deep learning package* (.dlpk) akan dijadikan data masukan ada proses klasifikasi piksel untuk mendeteksi area terdampak oil seep pada foto udara; (2) Proses pelatihan model dengan metode *deep learning* jenis *convolutional neural networks* untuk klasifikasi piksel pada foto udara menghasilkan akurasi sebesar 93% *epoch* ke-6 dianggap sebagai *epoch* paling optimum dalam klasifikasi. Tahap ini menghasilkan dokumen dengan format *deep learning package* yang nantinya dapat digunakan kembali pada data lain yang karakteristik wilayah yang mirip dan tujuan yang sama, yakni klasifikasi piksel untuk tutupan lahan area terdampak oil seep di darat; (3) Hasil klasifikasi piksel menghasilkan tampilan pendeteksian dalam bentuk raster, yang menunjukkan hasil kurang baik untuk tutupan lahan karena poligon tidak seluruhnya menutup.

B. Saran

Adapun saran yang diberikan pada penelitian selanjutnya adalah sebagai berikut: (1) Menambah *training sampel* agar yang terdeteksi lebih banyak pula. Hal ini perlu memperhatikan spesifikasi computer untuk pengolahan data karena membutuhkan waktu yang lebih lama dan penyimpanan yang lebih besar; (2) Melakukan proses *image enhancement* setelah melakukan proses klasifikasi piksel dengan tujuan untuk memperbaiki poligon hasil deteksi agar

tampilan lebih baik; (3) Melakukan perhitungan uji akurasi klasifikasi dengan *confusion matrix* agar dapat mengetahui tingkat akurasi hasil pendeteksian yang didapat; (4) Membandingkan data dengan data atau metode lain untuk mengetahui keunggulan metode CNN dari metode lain untuk pendeteksian area terdampak *oil seep*.

DAFTAR PUSTAKA

- [1] S. Sulistyono and M. Masykuri, "Kajian dampak tumpahan minyak dari kegiatan operasi kilang minyak terhadap kualitas air dan tanah (Studi Kasus Kilang Minyak Pusdiklat Migas Cepu)," *J. Ekosains*, vol. 4, no. 2, pp. 23–34, 2012.
- [2] S. Suprpti, "Penyelesaian sengketa pengelolaan sumur tua secara tradisional oleh masyarakat di desa Wonocolo Bojonegoro ditinjau dari aspek hukum," *J. Sos. Hum.*, vol. 4, no. 2, pp. 121–134, 2011.
- [3] S. T. Yekeen, A.-L. Balogun, and K. B. W. Yusof, "A novel deep learning instance segmentation model for automated marine oil spill detection," *ISPRS J. Photogramm. Remote Sens.*, vol. 167, pp. 190–200, 2020.
- [4] K. Wikantika and T. M. Susantoro, "Peranan Teknologi Penginderaan Jauh Pada Kegiatan Minyak Dan Gas Bumi," Institut Teknologi Bandung, 2017.
- [5] I. W. S. E. Putra, A. Y. Wijaya, and R. Soelaiman, "Klasifikasi Citra Menggunakan Convolutional Neural Network (CNN) pada Caltech 101," Institut Teknologi Sepuluh Nopember, 2016.
- [6] S. Timilsina, S. K. Sharma, and J. Aryal, "Mapping urban trees within cadastral parcels using an object-based convolutional neural network," *ISPRS Ann. Photogramm. Remote Sens. Spat. Inf. Sci.*, vol. 4, pp. 111–117, 2019.