

# Arsitektur U-Net Untuk Mendeteksi Titik Api Kebakaran Hutan Dan Lahan Di Kalimantan Tengah Menggunakan Satelit Himawari 8

Baharuddin<sup>1</sup>, Andi Patombongi<sup>2\*</sup>, Andi Tenriawaru<sup>3</sup>, Cakra<sup>4</sup>, Andi Muh Islah<sup>5</sup>

<sup>1,2,4,5</sup>Program Studi Sistem Komputer, STMIK Catur Sakti Kendari

<sup>3</sup>Program Studi Ilmu Komputer, Fakultas MIPA, Universitas Halu Oleo

## ABSTRACT

*Early detection of fire hotspots is crucial to prevent the spread of fires and to mitigate the resulting environmental impacts. This study proposes the use of the U-Net model for detecting fire hotspots on Himawari 8 satellite imagery, specifically utilizing Band 7, which is sensitive to thermal radiation. Fire hotspot data from MODIS and VIIRS were employed as the ground truth to validate the model predictions. The U-Net model was trained on satellite imagery with binary crossentropy as the loss function and was evaluated using Area Under Curve (AUC), Percentage Correct (PC), Omission Error (OE), and Commission Error (CE) as evaluation metrics. The training results demonstrate that the model is capable of detecting fire hotspots with high accuracy, achieving an AUC of over 0.85 on the validation data after 300 epochs. Moreover, PC increased and OE decreased, indicating an improvement in the model's ability to accurately detect fire hotspots. In conclusion, the U-Net model developed in this study has shown good performance in detecting fire hotspots.*

**Keywords:** U-Net, Detecting Fire Hotspots, Forest Fires, Himawari 8 Satellite, Central Kalimantan.

## ABSTRAK

Deteksi dini titik api menjadi sangat penting untuk mencegah penyebaran kebakaran yang lebih luas dan mengurangi dampak lingkungan yang ditimbulkan. Penelitian ini mengusulkan penggunaan model U-Net untuk mendeteksi titik api pada citra satelit Himawari 8, khususnya dengan menggunakan Band 7, yang sensitif terhadap radiasi termal. Data titik api dari MODIS dan VIIRS digunakan sebagai *ground truth* untuk memvalidasi prediksi model. Model U-Net dilatih menggunakan citra satelit dengan *metric binary crossentropy* sebagai fungsi *loss*, dan dievaluasi menggunakan metrik Area Under Curve (AUC), Percentage Correct (PC), Omission Error (OE), dan Commission Error (CE). Hasil pelatihan menunjukkan bahwa model dapat mendeteksi titik api dengan akurasi yang tinggi, dengan AUC mencapai lebih dari 0.85 pada data validasi setelah 300 *epoch*. Selain itu, PC meningkat dan OE menurun, yang menandakan peningkatan kemampuan model dalam mendeteksi titik api secara akurat. Kesimpulannya, model U-Net yang dikembangkan dalam penelitian ini mampu mendeteksi titik api dengan performa yang baik.

**Kata Kunci:** U-Net, Deteksi Titik Api, Kebakaran Hutan, Satelit Himawari 8, Kalimantan Tengah.

---

Corresponding Author E-mail: tomfiq@gmail.com\*

Received Oktober 2024; revised Oktober 2024; accepted November 2024; published Januari 2025

## 1. Pendahuluan

Kebakaran hutan dan lahan terjadi hampir setiap tahun di Indonesia, terutama di wilayah Kalimantan [1]. Salah satu wilayah di Indonesia yang sering terjadi kebakaran hutan adalah Kalimantan Tengah, berdasarkan data dari Kementerian Lingkungan Hidup dan Kehutanan pada tahun 2015 luas kebakaran mencapai 583.833,44 hektar. Mendeteksi titik api kebakaran hutan lebih dini memiliki beberapa manfaat yang signifikan, diantaranya dapat diambil langkah-langkah penanggulangan yang cepat untuk mencegah penyebaran api, hal ini membantu mencegah kerusakan lingkungan yang lebih luas, termasuk hilangnya habitat satwa liar, kerusakan ekosistem, dan degradasi tanah. Manfaat lain dari deteksi titik api adalah petugas pemadam kebakaran dapat segera merespon dan mengendalikan kebakaran sebelum menyebabkan kerugian yang lebih besar.

Dalam penelitian ini kami mengusulkan metode baru dalam mendeteksi titik api yaitu dengan menggunakan arsitektur U-Net [2] untuk mendeteksi titik api dengan menggunakan band atau saluran 7 pada citra satelit Himawari 8. Kami lebih memilih menggunakan metode *deep learning*, terutama Convolutional Neural Networks (CNN), dikarenakan sangat baik dalam mengenali pola spasial dan spektral yang kompleks dalam citra satelit. *Deep learning* mampu menggabungkan berbagai sumber informasi (misalnya data inframerah, data visibel, dan data temporal) untuk deteksi yang lebih akurat dan kaya informasi.

## 2. Tinjauan Pustaka

Pantauan titik api kebakaran hutan di Indonesia saat ini menggunakan satelit polar seperti Terra, Aqua, dan Suomi NPP[3]. Satelit Terra dan Aqua menggunakan sensor MODIS (Moderate Resolution Imaging Spectroradiometer), sementara satelit Suomi NPP menggunakan sensor VIIRS (Visible Infrared Imaging Radiometer Suite) untuk mendeteksi kebakaran hutan dan lahan. Selain menggunakan satelit polar beberapa pemantauan titik api kebakaran hutan dan lahan menggunakan satelit *geostasioner* [4]–[7].

MODIS, yang telah beroperasi sejak awal 2000-an, menggunakan algoritma deteksi anomali termal yang terutama mengandalkan saluran inframerah tengah untuk mengidentifikasi kebakaran aktif. Instrumen ini menyediakan data empat kali sehari, yang bermanfaat untuk memantau kejadian kebakaran di area yang luas. Namun, kemampuan deteksinya terbatas oleh resolusi spasial sekitar 1 km, yang dapat menyebabkan terlewatnya kebakaran yang lebih kecil dan kebakaran yang tertutup oleh asap atau awan [8], [9]. Penelitian telah menunjukkan bahwa MODIS cenderung tidak mendeteksi kebakaran yang lebih kecil, terutama di daerah dengan biomassa rendah, yang mengakibatkan pelaporan yang kurang akurat terkait kekuatan radiasi

kebakaran (FRP) [10]. Peningkatan algoritma pada MODIS Collection 6 bertujuan untuk mengurangi kesalahan deteksi dan meningkatkan akurasi deteksi, namun tantangan tetap ada, terutama dalam mendeteksi kebakaran dengan intensitas yang lebih rendah [9].

Sebaliknya, VIIRS, yang beroperasi dengan resolusi spasial lebih halus sebesar 375 m, telah menunjukkan kemampuan yang lebih unggul dalam mendeteksi kebakaran yang lebih kecil dan lebih dingin dibandingkan dengan MODIS. Hal ini terutama disebabkan oleh skema agregasi piksel yang lebih canggih dan penyertaan data 1-band, yang memungkinkan deteksi kebakaran yang secara signifikan lebih kecil dibandingkan dengan yang dapat dideteksi oleh MODIS [11], [12]. Penelitian menunjukkan bahwa VIIRS dapat mendeteksi kebakaran dengan tingkat yang jauh lebih tinggi daripada MODIS, dengan hasil penelitian yang menunjukkan faktor deteksi 7,2 kali lebih tinggi di Asia Selatan dan 5,12 kali lebih tinggi di Asia Tenggara [11]. Kemampuan deteksi yang ditingkatkan ini memiliki implikasi penting dalam pemahaman dinamika kebakaran dan kontribusinya terhadap emisi gas rumah kaca serta kualitas udara [11], [12].

Selain itu, kinerja kedua sistem ini dapat bervariasi berdasarkan waktu dalam sehari. VIIRS diketahui memiliki kemampuan yang lebih baik dalam mendeteksi kebakaran pada malam hari dibandingkan dengan MODIS, menunjukkan bahwa VIIRS mungkin dapat menangkap keberlangsungan kebakaran dalam jangka waktu yang lebih lama atau kebakaran yang terjadi pada malam hari [13], [14]. Kemampuan ini sangat penting untuk pemantauan kebakaran yang komprehensif, terutama di wilayah di mana aktivitas kebakaran memuncak pada malam hari.

Meskipun ada kemajuan ini, baik MODIS maupun VIIRS menghadapi tantangan terkait deteksi kebakaran palsu dan akurasi estimasi luas kebakaran. Misalnya, meskipun VIIRS dapat mendeteksi lebih banyak kebakaran, sistem ini juga rentan terhadap alarm palsu, terutama di lanskap yang kompleks [13], [15]. Selain itu, penelitian yang membandingkan kedua sistem ini menunjukkan bahwa meskipun VIIRS mendeteksi lebih banyak kebakaran, total kekuatan radiasi kebakaran (FRP) yang dilaporkan kadang-kadang lebih rendah dibandingkan dengan MODIS untuk kebakaran yang terdeteksi oleh kedua sensor, yang menunjukkan adanya kompleksitas dalam karakterisasi kebakaran antara kedua sistem tersebut [10].

Satelit meteorologi *geostasioner*, terutama Himawari-8, menawarkan beberapa keunggulan dibandingkan satelit polar dalam konteks deteksi kebakaran. Keunggulan ini terutama berasal dari karakteristik operasionalnya yang unik, termasuk resolusi temporal yang tinggi, kemampuan pemantauan kontinu, dan integrasi data yang lebih baik untuk manajemen

kebakaran. Salah satu keunggulan paling signifikan dari Himawari-8 adalah resolusi temporalnya yang tinggi. Satelit ini menyediakan citra cakupan penuh setiap 10 menit, yang sangat penting untuk memantau kondisi dan dinamika kebakaran yang berubah dengan cepat [16], [17]. Kemampuan kunjungan ulang yang sering ini memungkinkan deteksi kebakaran baru secara tepat waktu dan penilaian perilaku kebakaran secara real-time, memungkinkan para responden darurat untuk membuat keputusan yang cepat dan tepat. Sebaliknya, satelit polar biasanya memiliki waktu kunjungan ulang yang lebih lama, sering kali hanya mengambil data sekali atau dua kali sehari, yang dapat mengakibatkan hilangnya peluang untuk memantau perkembangan kebakaran yang kritis [18], [19].

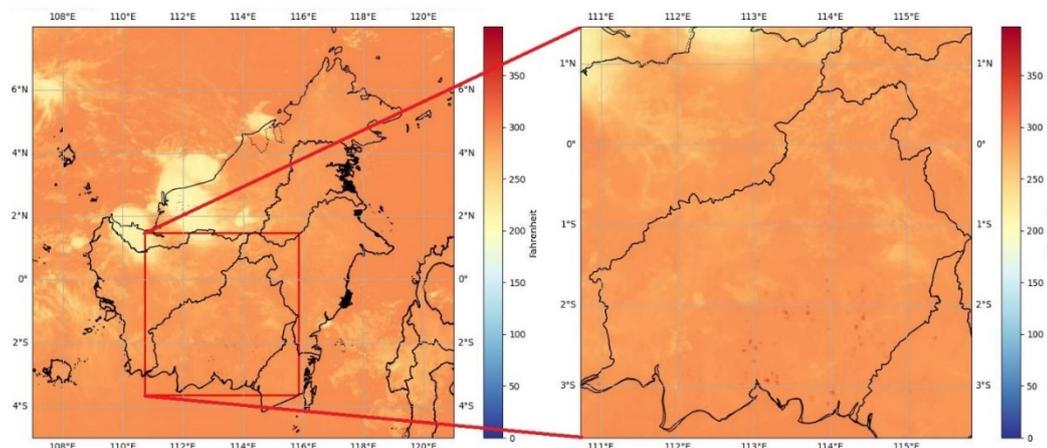
Penelitian terakhir yang dilakukan di Kalimantan dalam konteks pendeteksian titik api kebakaran hutan dan lahan dilakukan oleh [5] dengan menggunakan metode *thresholding* dengan menggunakan citra satelit Himawari 8. *Thresholding* adalah metode yang sederhana dan menggunakan pendekatan satu dimensi (biasanya berdasarkan suhu atau nilai piksel tunggal). Metode

*thresholding* tidak mampu menganalisis pola yang lebih kompleks dalam citra satelit, seperti hubungan antara berbagai saluran spektral, pola spasial, atau dinamika temporal.

### 3. Metode

#### 3.1 Lokasi Penelitian

Penelitian ini dilakukan di Provinsi Kalimantan. Secara geografis, Kalimantan berada di antara  $0^{\circ}45'$  Lintang Utara hingga  $3^{\circ}30'$  Lintang Selatan dan  $111^{\circ}$  -  $116^{\circ}$  Bujur Timur. Provinsi Kalimantan Tengah adalah provinsi terbesar kedua di Indonesia dengan luas wilayah  $153.564 \text{ km}^2$ , dan Palangka Raya sebagai ibukotanya. Wilayah ini terdiri dari kawasan hutan seluas  $12.675.364 \text{ Ha}$  atau  $82,16\%$ , sedangkan kawasan non-kehutanan mencakup  $2.751.416 \text{ Ha}$  atau  $17,84\%$ . Dalam penelitian ini Untuk mencapai ukuran gambar input dan output sebesar  $256 \times 256$  piksel (resolusi spasial  $0,02^{\circ}$ ), area tersebut didefinisikan antara lintang  $3,65^{\circ}$  LS hingga  $1,46^{\circ}$  LU dan bujur  $110,73^{\circ}$  BT hingga  $115,85^{\circ}$  BT (Gambar 1).



Gambar 1. Lokasi penelitian

#### 3.2. Data Satelit Himawari 8

Data satelit himawari 8 dapat diakses oleh peneliti secara bebas atau bersifat *open*, area data satelit himawari meliputi lintang dari  $600$  Selatan hingga  $600$  Utara, serta bujur dari  $800$  Timur hingga  $1600$  Barat, untuk wilayah Indonesia resolusi spasial yang disediakan oleh himawari ada 2 yaitu resolusi  $2 \text{ km}$  dan  $5 \text{ km}$ , untuk resolusi temporalnya adalah  $10$  menit. Data citra satelit yang akan diambil adalah selama tiga bulan yaitu bulan Agustus, September, dan Oktober pada tahun 2019 dan fokus pada Provinsi Kalimantan Tengah, seperti yang dilakukan oleh [5] untuk dapat membandingkan hasil yang diperoleh. Seluruh data dibagi menjadi tiga set: pelatihan, validasi, dan pengujian. Untuk proporsi pembagian data adalah

$80\%$  untuk pelatihan serta validasi dan  $20\%$  untuk pengujian.

Dalam penelitian ini kami menggunakan band 7 dengan Panjang gelombang  $3,9 \mu\text{m}$  untuk mendeteksi titik api (*fire detection*), dikarenakan sensitif terhadap radiasi inframerah termal. Band ini dirancang untuk mendeteksi berbagai fenomena termasuk permukaan (*surface*), awan (*cloud*), kabut di malam hari (*fog at night*), angin (*winds*), dan kebakaran atau titik api [20].

#### 3.3. Data MODIS dan VIIRS

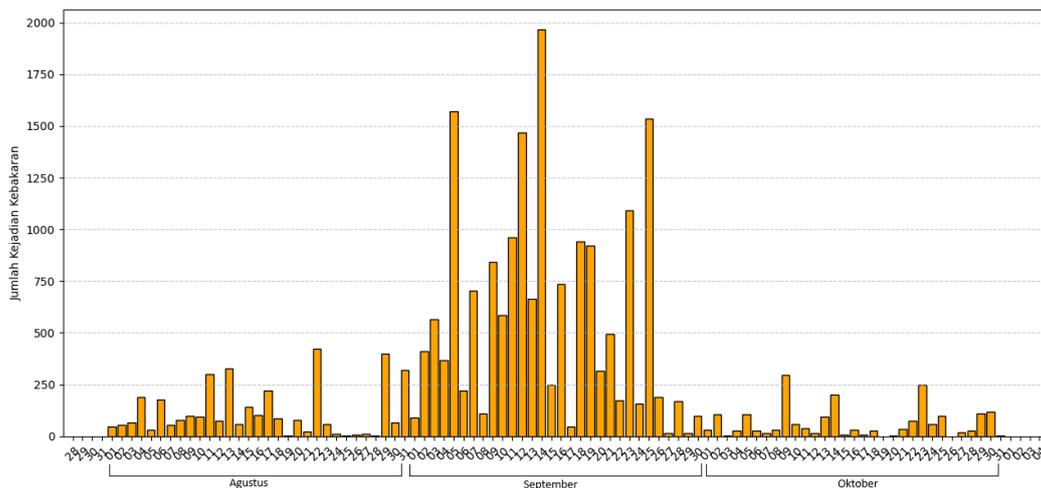
Data titik panas dari MODIS dan VIIRS diambil dari situs FIRMS NASA, yang mencakup informasi tentang koordinat lokasi (*Latitude* dan *Longitude*), suhu

kecerahan, waktu akuisisi, jenis satelit, tipe sensor, tingkat kepercayaan, versi algoritma, suhu kecerahan pada saluran termal, serta *fire radiative power*. Data MODIS dan VIIRS digunakan sebagai data *ground truth* yaitu data referensi atau data nyata yang dikumpulkan langsung dari pengamatan atau pengukuran di lapangan, dan digunakan untuk memvalidasi prediksi titik api dari model yang dibangun. Dari data yang diperoleh distribusi total titik api perharinya dapat terlihat pada Gambar 2. Pada bulan September 2019, terjadi lonjakan signifikan dalam jumlah kejadian kebakaran, terutama sekitar pertengahan bulan. Ada beberapa hari dengan jumlah titik api yang sangat tinggi, mencapai hampir 2000 kejadian pada satu hari tertentu. Bulan Agustus menunjukkan adanya kebakaran, namun jumlahnya lebih bervariasi dan tidak setinggi pada bulan September. Pada bulan Oktober, jumlah kebakaran menurun drastis dibandingkan dengan September, meskipun masih ada beberapa hari dengan jumlah kejadian yang cukup tinggi. Total kejadian kebakaran adalah 2309, 11990 dan 1150 secara berurutan dari Bulan Agustus, September dan Oktober.

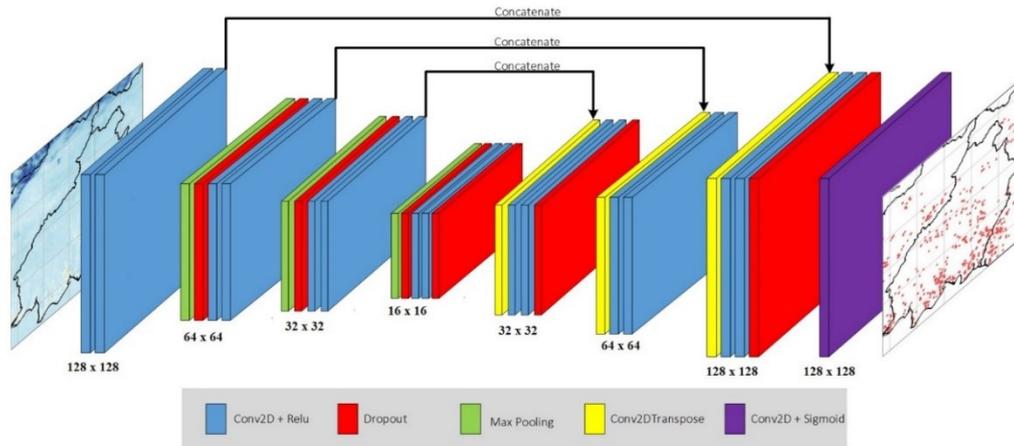
### 3.4. Model U-Net

Jaringan U-Net awalnya dirancang untuk segmentasi semantik, yang mencakup pemberian label kelas pada setiap piksel dalam gambar [2]. Dibangun di

atas kerangka jaringan konvolusi penuh, U-Net menggunakan arsitektur *encoder-decoder* untuk secara efisien menangkap informasi kontekstual multi-skala dari gambar. Seperti yang ditunjukkan pada Gambar 3, model U-Net diimplementasikan menggunakan kerangka kerja Keras TensorFlow. Lapisan input terdiri dari gambar satelit dengan 1 saluran yaitu band 7 pada citra satelit. Selain itu, model ini diatur menjadi 2 bagian utama, yaitu *encoder* (sisi kiri) dan *decoder* (sisi kanan). *Encoder* bertanggung jawab untuk ekstraksi fitur dan terdiri dari beberapa blok konvolusi. Setiap blok berisi 2 lapisan konvolusi  $3 \times 3$ , fungsi aktivasi ReLU, diikuti oleh lapisan *max-pooling* dengan *stride* 2 untuk *down-sampling*. Pada setiap tahap *down-sampling*, jumlah saluran fitur digandakan (16, 32, dan 64 filter). Setelah proses ini, lapisan *dropout* dimasukkan untuk mengurangi *overfitting* melalui *encoder*. Bagian *bottleneck* berisi 2 lapisan konvolusi dengan 128 filter dan tingkat *dropout* sebesar 0,3. Komponen *decoder* melakukan operasi *up-sampling* yang penting untuk mengurangi jumlah saluran fitur. Selain itu, *skip connection* dimasukkan untuk menjembatani *encoder* dan *decoder*, memfasilitasi kombinasi peta fitur berdimensi rendah dengan yang berdimensi tinggi. Pada lapisan terakhir, satu filter konvolusi dengan aktivasi *sigmoid* diterapkan untuk menghasilkan prediksi citra titik api dari data satelit.



**Gambar 2.** Distribusi total titik api per hari selama 3 bulan (Agustus, September dan Oktober) 2019



Gambar 3. Model U-Net yang digunakan dalam penelitian.

### 3.5. Pelatihan dan Pengujian Model

Model U-Net dikembangkan dan dilatih menggunakan Keras dengan TensorFlow sebagai *backend*. Untuk proses pelatihannya, model dikompilasi dengan *optimizer* Adam, dimulai dengan laju pembelajaran awal sebesar 0,0001. Dalam penelitian ini, *binary crossentropy* digunakan sebagai fungsi *loss*, sementara Area Under Curve, Percentage Correct, Omission Error, Commission Error digunakan sebagai metrik evaluasi. AUC digunakan untuk mengevaluasi performa model secara keseluruhan dalam mendeteksi titik api pada citra satelit. Dalam hal ini, ROC curve akan menggambarkan *trade-off* antara True Positive Rate (TPR) (piksel yang benar diklasifikasikan sebagai titik api) dan False Positive Rate (FPR) piksel non-titik api yang salah diklasifikasikan sebagai titik api). Semakin tinggi AUC, semakin baik model dalam membedakan antara piksel yang mengandung titik api dan yang tidak. AUC 1 menunjukkan model sempurna, sedangkan AUC 0,5 menunjukkan performa yang setara dengan model acak. Percentage Correct (PC) pada persamaan (1) mengukur persentase piksel yang diklasifikasikan dengan benar, baik sebagai titik api (positif) maupun bukan titik api (negatif). Ini memberikan gambaran umum tentang akurasi model dalam mengklasifikasikan setiap piksel dalam citra. Omission Error (OE) pada persamaan (2) mengukur proporsi titik api yang seharusnya terdeteksi tetapi tidak terdeteksi oleh model (False Negative). Ini berarti ada titik api yang terlewat oleh model sehingga tidak terklasifikasi sebagai titik api. Commission Error (CE) pada persamaan (3) mengukur proporsi piksel yang seharusnya bukan titik api tetapi diklasifikasikan sebagai titik api oleh model (False Positive). Ini berarti model "menambahkan" kesalahan dengan menganggap piksel yang tidak mengandung api sebagai titik api.

$$PC = \frac{TP+TN}{\text{Jumlah Total Pixel}} \quad (1)$$

$$OE = \frac{FN}{TP+FN} \quad (2)$$

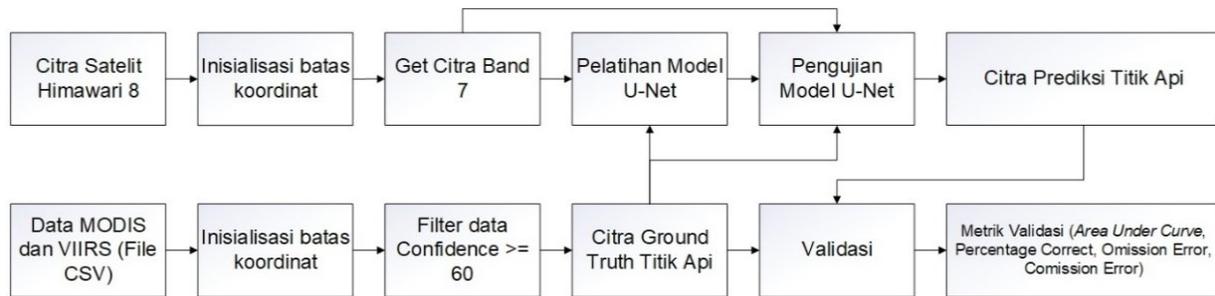
$$CE = \frac{FP}{TN+FP} \quad (3)$$

Dimana TP adalah jumlah pixel benar diprediksi model sebagai titik api, TN adalah jumlah piksel benar diprediksi model sebagai bukan titik api, FP adalah jumlah piksel salah diprediksi model sebagai titik api, dan FN adalah jumlah piksel salah diprediksi model sebagai bukan titik api.

Alur kerja dari proses pelatihan model dan pengujian model yang dikembangkan dapat dilihat pada Gambar 4. Band 7 dari citra satelit digunakan sebagai input, sementara data dari MODIS dan VIIRS dari NASA digunakan sebagai *ground truth* untuk pelatihan dan validasi model. Langkah pertama adalah mengumpulkan citra satelit dari Himawari 8. Citra satelit ini berfungsi sebagai input utama untuk mendeteksi titik api. Himawari 8 memiliki banyak band spektral, dan dalam kasus ini, Band 7 dipilih karena biasanya sensitif terhadap suhu permukaan, sehingga cocok untuk mendeteksi anomali panas seperti titik api atau kebakaran. Setelah citra satelit diperoleh, dilakukan inialisasi batas koordinat antara lintang 3,65° LS hingga 1,46° LU dan bujur 110,73° BT hingga 115,85° BT. Model U-Net kemudian dilatih menggunakan citra Band 7 dari Himawari 8. U-Net adalah model jaringan saraf konvolusi yang sering digunakan dalam segmentasi gambar, yang dalam kasus ini bertujuan untuk memisahkan piksel yang termasuk titik api dari yang tidak. *Hyperparameter* yang digunakan dalam pelatihan adalah *learning\_rate* = 0.0001, *loss* = binary crossentropy, *epochs* = 300, *batch\_size* = 16. Data MODIS dan VIIRS yang digunakan sebagai *ground truth* harus difilter berdasarkan *confidence* (kepercayaan). Hanya data dengan tingkat kepercayaan di atas 60 yang digunakan, yang berarti hanya titik api yang terdeteksi dengan kepercayaan tinggi yang akan dipertimbangkan dalam validasi. Setelah data dari MODIS dan VIIRS difilter, langkah berikutnya adalah membentuk citra *ground truth* yang akan digunakan untuk membandingkan hasil prediksi model U-Net. Citra

*ground truth* ini menunjukkan lokasi titik api yang sebenarnya berdasarkan data dari MODIS dan VIIRS. Pada tahap validasi, citra prediksi titik api dari model U-Net dibandingkan dengan citra *ground truth*. Tujuannya

adalah untuk mengukur seberapa baik model U-Net dapat mendeteksi titik api dengan benar. Tahap pengujian akan memberikan nilai *metric* Area Under Curve, Percentage Correct, Omission Error, Commission Error.



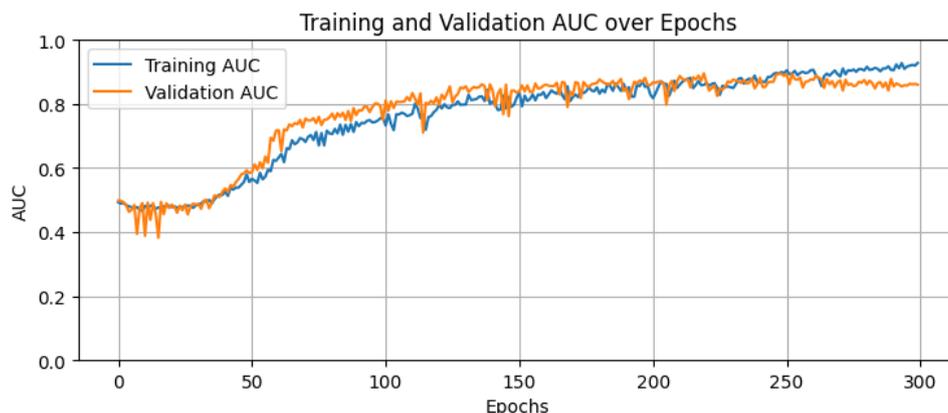
**Gambar 4.** Alur kerja penelitian

#### 4. Hasil dan Pembahasan

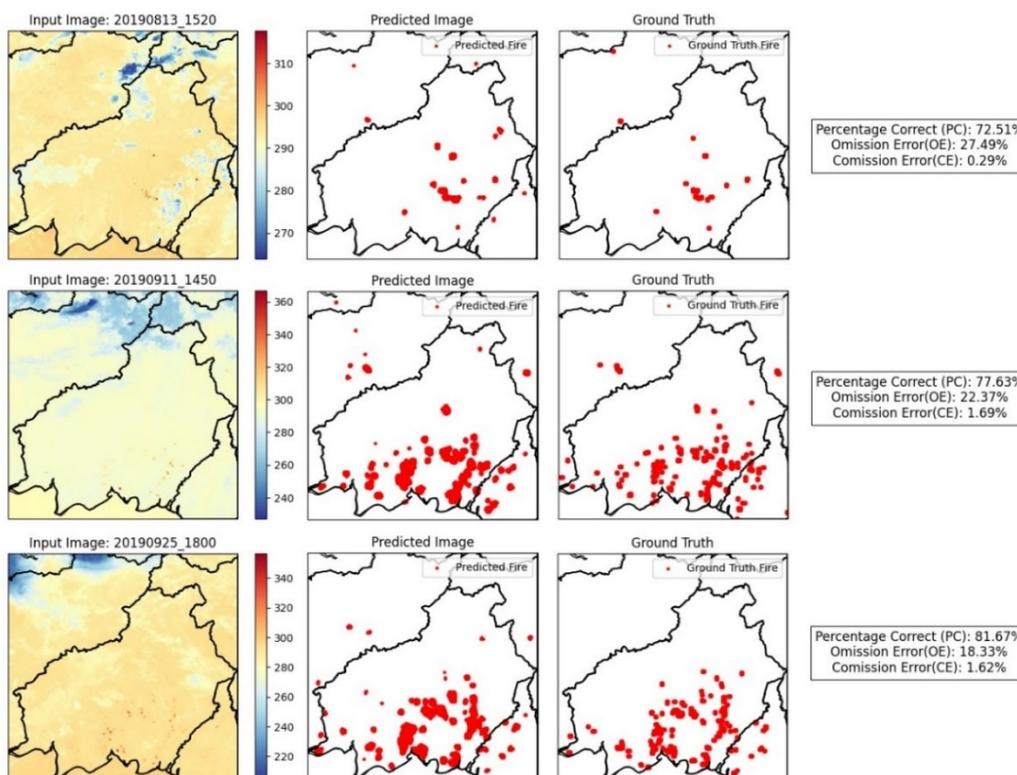
Salah satu hasil pengujian yang didapatkan untuk mengetahui kinerja model yang dikembangkan adalah *metric* AUC (Area Under the Curve) yang dapat dilihat pada Gambar 5. Pada awal pelatihan, AUC untuk training dimulai pada nilai yang rendah (sekitar 0,5) dan secara bertahap ketika mendekati epoch 300 nilai AUC meningkat seiring bertambahnya epoch. Ini menunjukkan bahwa model awalnya memiliki kinerja yang buruk dalam membedakan piksel titik api dan bukan titik api, tetapi belajar dengan cukup cepat. AUC untuk validation menunjukkan fluktuasi yang lebih besar pada tahap awal ini. Fluktuasi ini bisa menunjukkan bahwa model masih menyesuaikan diri dengan data validasi dan belum sepenuhnya stabil dalam membuat prediksi yang akurat. Pada periode epoch 50 - 150, AUC untuk pelatihan terus meningkat dengan stabil, mencapai sekitar 0,8–0,9, menunjukkan peningkatan yang signifikan dalam kemampuan model untuk memisahkan titik api dari bukan titik api. AUC untuk validation juga mengalami peningkatan yang signifikan selama periode ini dan mencapai nilai yang sama dengan AUC untuk training. Pada sekitar epoch 100, nilai AUC validasi mulai lebih stabil, namun masih ada beberapa penurunan tajam yang mungkin mengindikasikan *overfitting* sementara pada model. Di akhir pelatihan, AUC untuk training terus meningkat secara bertahap hingga mendekati 0,95, yang menunjukkan model semakin kuat dalam memprediksi titik api dengan akurasi yang tinggi pada data training. AUC untuk validation tampak stabil dengan nilai yang konsisten sekitar 0,85 hingga 0,9, tetapi mengalami sedikit penurunan dan fluktuasi kecil. Ini menunjukkan bahwa model mungkin sudah mencapai batas kinerja optimalnya pada data validasi, dan penurunan kecil ini mungkin disebabkan oleh *overfitting* terhadap data training. AUC training terus meningkat mendekati 1,0,

sedangkan AUC validation cenderung stabil di kisaran 0,85-0,9. Hal ini menunjukkan bahwa model kemungkinan mengalami sedikit *overfitting*, di mana model terlalu baik dalam menangani data training, namun tidak selalu merefleksikan kinerja yang sama pada data validasi.

Untuk memberikan visualisasi yang jelas tentang bagaimana model U-Net mendeteksi titik api dari citra satelit (input image) dan bagaimana prediksi ini dibandingkan dengan *ground truth* (data sebenarnya yang diperoleh dari MODIS/VIIRS) kami mencoba menampilkan 3 sampel data uji yang memvisualisasikan prediksi model dan *ground truth* secara berdampingan seperti terlihat pada Gambar 6 untuk melihat seberapa baik model bekerja secara kualitatif. Kolom 1 (input image) merupakan citra satelit dari Band 7 Himawari 8 yang digunakan sebagai input ke model. Kolom 2 (predicted image) merupakan hasil prediksi model U-Net, titik api yang terdeteksi oleh model ditampilkan dalam warna merah. Kolom 3 (ground truth) merupakan lokasi titik api yang sebenarnya (dari data MODIS/VIIRS) yang juga ditampilkan dalam warna merah. Dari sampel pertama hingga sampel ketiga, model menunjukkan peningkatan dalam PC dan penurunan OE, yang berarti model menjadi lebih akurat dalam mendeteksi titik api dan semakin sedikit melewatkan titik api yang sebenarnya. CE tetap rendah di seluruh sampel, menunjukkan bahwa model jarang membuat kesalahan dengan salah mengklasifikasikan piksel yang bukan titik api sebagai titik api (false positives). Secara keseluruhan, hasil pengujian ini menunjukkan bahwa model U-Net bekerja dengan baik dalam mendeteksi titik api, meskipun ada beberapa titik api yang terlewat, terutama pada sampel pertama. Namun, kinerja model semakin membaik pada sampel kedua dan ketiga.



Gambar 5. AUC (Area Under the Curve).



Gambar 6. Perbandingan hasil deteksi titik api: prediksi model vs. *ground truth*.

### 5. Penutup

Penelitian ini berhasil mengembangkan model U-Net yang efektif untuk mendeteksi titik api di kawasan Kalimantan Tengah dengan menggunakan Band 7 dari citra satelit Himawari 8. Model ini dilatih menggunakan data citra satelit yang dipadukan dengan data *ground truth* dari MODIS dan VIIRS untuk memvalidasi prediksi titik api. Evaluasi kinerja model menggunakan metrik AUC (Area Under Curve), Percentage Correct (PC), Omission Error (OE), dan Commission Error (CE) menunjukkan bahwa model mampu mendeteksi titik api dengan tingkat akurasi yang tinggi, dengan peningkatan kinerja yang signifikan seiring dengan bertambahnya epoch pelatihan.

Hasil pengujian menunjukkan bahwa model berhasil mendeteksi sebagian besar titik api dengan tingkat PC yang meningkat secara bertahap dan OE yang menurun dari sampel ke sampel, yang menunjukkan peningkatan keakuratan model dalam mendeteksi titik api seiring waktu. Commission Error (CE) tetap rendah sepanjang pengujian, yang menunjukkan bahwa model jarang membuat kesalahan dalam mengklasifikasikan piksel non-titik api sebagai titik api.

Kesimpulannya, model U-Net yang dikembangkan dalam penelitian ini terbukti efektif dalam mendeteksi titik api di wilayah Kalimantan Tengah dan dapat digunakan sebagai alat yang berguna dalam mendukung sistem pemantauan kebakaran hutan. Meskipun masih ada beberapa titik api yang terlewatkan, performa model

secara keseluruhan menunjukkan potensi besar untuk aplikasi di masa depan, terutama dalam sistem deteksi dini kebakaran.

## 6. Daftar Pustaka

- [1] N. Yulianti, H. Hayasaka, and A. Sepriando, "Recent trends of fire occurrence in Sumatra (analysis using MODIS hotspot data): a comparison with fire occurrence in Kalimantan," *Open J. For.*, vol. 3, no. 4, pp. 129–137, 2013.
- [2] O. Ronneberger, P. Fischer, and T. Brox, "U-net: Convolutional networks for biomedical image segmentation," in *International Conference on Medical image computing and computer-assisted intervention*, Springer, 2015, pp. 234–241.
- [3] L. Penerbangan and A. Nasional, "Informasi Titik Panas (Hotspot) Kebakaran Hutan atau Lahan," *Bogor Deputi Bid. Penginderaan Jauh-LAPAN*, 2016.
- [4] T. Wati and A. Panjaitan, "Forest fires detection in Indonesia using satellite Himawari-8 (case study: Sumatera and Kalimantan on august-october 2015)," in *IOP Conference Series: Earth and Environmental Science*, IOP Publishing, 2017, p. 12053.
- [5] A. Sepriando, H. Hartono, and R. H. Jatmiko, "Deteksi kebakaran hutan dan lahan menggunakan citra satelit himawari-8 di Kalimantan Tengah," *J. Sains Teknol. Modif. Cuaca*, vol. 20, no. 2, pp. 79–89, 2019.
- [6] Z. Xie, W. Song, R. Ba, X. Li, and L. Xia, "A spatiotemporal contextual model for forest fire detection using Himawari-8 satellite data," *Remote Sens.*, vol. 10, no. 12, p. 1992, 2018.
- [7] E. Jang, Y. Kang, J. Im, D.-W. Lee, J. Yoon, and S.-K. Kim, "Detection and monitoring of forest fires using Himawari-8 geostationary satellite data in South Korea," *Remote Sens.*, vol. 11, no. 3, p. 271, 2019.
- [8] J.-L. Devineau, A. Fournier, and S. Nignan, "Savanna Fire Regimes Assessment With MODIS Fire Data: Their Relationship to Land Cover and Plant Species Distribution in Western Burkina Faso (West Africa)," *J. Arid Environ.*, vol. 74, no. 9, pp. 1092–1101, 2010, doi: 10.1016/j.jaridenv.2010.03.009.
- [9] L. Giglio, W. Schroeder, and C. O. Justice, "The Collection 6 MODIS Active Fire Detection Algorithm and Fire Products," *Remote Sens. Environ.*, vol. 178, pp. 31–41, 2016, doi: 10.1016/j.rse.2016.02.054.
- [10] Y. Fu *et al.*, "Fire detection and fire radiative power in forests and low-biomass lands in Northeast Asia: MODIS versus VIIRS Fire Products," *Remote Sens.*, vol. 12, no. 18, p. 2870, 2020.
- [11] K. P. Vadrevu, K. Lasko, L. Giglio, W. Schroeder, S. Biswas, and C. Justice, "Trends in Vegetation Fires in South and Southeast Asian Countries," *Sci. Rep.*, vol. 9, no. 1, 2019, doi: 10.1038/s41598-019-43940-x.
- [12] K. P. Vadrevu and K. Lasko, "Intercomparison of MODIS AQUA and VIIRS I-Band Fires and Emissions in an Agricultural Landscape—Implications for Air Pollution Research," *Remote Sens.*, vol. 10, no. 7, p. 978, 2018, doi: 10.3390/rs10070978.
- [13] K. Vadrevu, "Trends in Nighttime Fires in South/Southeast Asian Countries," *Atmosphere (Basel)*, vol. 15, no. 1, p. 85, 2024, doi: 10.3390/atmos15010085.
- [14] P. H. Freeborn, W. M. Jolly, M. A. Cochrane, and G. Roberts, "Large Wildfire Driven Increases in Nighttime Fire Activity Observed Across CONUS From 2003–2020," *Remote Sens. Environ.*, vol. 268, p. 112777, 2022, doi: 10.1016/j.rse.2021.112777.
- [15] E. Scaduto, Б. ЧЭН, and Y. Jin, "Satellite-Based Fire Progression Mapping: A Comprehensive Assessment for Large Fires in Northern California," *Ieee J. Sel. Top. Appl. Earth Obs. Remote Sens.*, vol. 13, pp. 5102–5114, 2020, doi: 10.1109/jstars.2020.3019261.
- [16] H. Xu, Z. Gui, Z. Zhou, X. Zhou, and C. Zhou, "Forest Fire Monitoring and Positioning Improvement at Subpixel Level: Application to Himawari-8 Fire Products," *Remote Sens.*, vol. 14, no. 10, p. 2460, 2022, doi: 10.3390/rs14102460.
- [17] Z. Hong *et al.*, "Active Fire Detection Using a Novel Convolutional Neural Network Based on Himawari-8 Satellite Images," *Front. Environ. Sci.*, vol. 10, 2022, doi: 10.3389/fenvs.2022.794028.
- [18] Y. Liang, L. Zhou, J. Chen, Y. Huang, R. Wei, and E. Zhou, "Monitoring and Risk Assessment of Wildfires in the Corridors of High-Voltage Transmission Lines," *Ieee Access*, vol. 8, pp. 170057–170069, 2020, doi: 10.1109/access.2020.3023024.
- [19] Z. Deng and Z. Gui, "An Improved Forest Fire Monitoring Algorithm With Three-Dimensional Otsu," *Ieee Access*, vol. 9, pp. 118367–118378, 2021, doi: 10.1109/access.2021.3105382.
- [20] A. Shimizu, "Introduction to Himawari-8 RGB composite imagery," *Meteorol. Satell. Cent. Tech. Note*, vol. 65, p. 42, 2020.