

Sistem Deteksi Kebakaran Hutan menggunakan E-nose Berbasis pada JST *Backpropagation*

Zandy Yudha Perwira^{*1}, Danang Lelono², Andi Dharmawan³

^{1,2,3}Department of Computer Science and Electronics, FMIPA UGM, Yogyakarta, Indonesia

e-mail: ^{*1}zandy.yudha.perwira@mail.ugm.ac.id, ²danang@ugm.ac.id,

³andi_dharmawan@ugm.ac.id

Abstrak

Indonesia memiliki hutan yang sangat luas yaitu 93,95 juta ha setara dengan 50% luas daratan Indonesia. Luasan hutan di Indonesia terus mengalami penurunan setiap tahunnya diakibatkan oleh kebakaran hutan. Maka untuk menekan penurunan kebakaran hutan diperlukan alat untuk mendeteksi kebakaran sedini mungkin dikarenakan kebakaran hutan jika sudah menyebar sulit untuk dipadamkan. Pendeteksian kebakaran hutan saat ini masih dilakukan manual dengan bantuan visual yang kurang dapat mendeteksi lebih dini. Penelitian tentang sistem detektor kebakaran hutan sangat perlu dikembangkan untuk menanggulangi kebakaran yang lebih besar. Pada penelitian ini, pendeteksian menggunakan sebuah electronic nose (e-nose), sensor suhu, kelembapan, serta debu untuk mendeteksi asap kebakaran hutan dan ditambah dengan sensor FLIR (Forward Looking Infrared) sebagai detektor dini kebakaran hutan.

Sensor-sensor membaca asap dalam bentuk sinyal dengan pola tertentu untuk tiap sampel asap. Pola-pola tersebut kemudian dilakukan prapemrosesan data dengan melakukan normalisasi baseline dan ekstraksi ciri 4 metode yang berbeda. Ciri yang didapat kemudian akan dikenali dengan menggunakan metode pengenalan pola yaitu Jaringan Saraf Tiruan (JST) *Backpropagation*. Proses pengenalan dilakukan dengan melakukan pelatihan untuk mencapai parameter-parameter yang optimal sehingga didapat model optimal. Pengujian model terbaik dengan beberapa titik api menghasilkan akurasi dalam membedakan jenis asap 98% untuk satu titik dan 100% untuk beberapa titik..

Kata kunci— Hutan, Kebakaran, JST, E-nose, FLIR

Abstract

Indonesia has very wide forest which is 93,5 million ha, equivalent of 50% area of Indonesia's land. The Indonesia's forest area continues getting smaller due to forest fire. So to suppress the forest fire is needed early detection system to detect forest fire as early as possible because forest fires, which have spread, are difficult to extinguish. Currently, forest fires are being detected manually with visual aids, not be able to detect it early. Research of forest fire detection system are really needed to be developed to prevent larger forest fire spread. In this study, Detection system uses an electronic nose (e-nose), sensor of temperature, humidity, and dust, and FLIR (Forward Looking Infrared) to early detect forest fires.

Sensors read smoke in form of signal with specific pattern for each sample of smoke. Next, these patterns are pre-processed data with performing baseline normalization and features extraction with 4 different methods. The features will be recognize by recognition method, named Artificial Neural Networks (ANN) *Backpropagation*. The recognition process is performed by training and testing to achieve optimal parameters to get optimal model. The testing got 98% accuracy to identify smoke of a hotspot and 100% smoke of some hotspots.

Keywords— Forest, Fire, JST, E-nose, FLIR

1. PENDAHULUAN

Indonesia memiliki luas daratan 187,75 juta ha dengan 93,95 juta ha atau 50%-nya merupakan hutan [1] yang terdiri dari hutan gambut dan non-gambut (bakau, sabana, musim, dan hujan tropis). Dari angka tersebut luas hutan hampir setiap tahun mengalami penurunan sebesar 904,324 ha menurut data dari tahun 2014 – 2019 akibat adanya kebakaran hutan [2]. Kebakaran hutan jika telah meluas sulit dilakukan pemadaman sehingga perlu adanya sebuah peringatan dini terjadinya kebakaran agar kebakaran tidak meluas.

Tanda awal kebakaran hutan perlu diketahui sebagai acuan dalam pembuatan peringatan dini kebakaran hutan. Tanda-tanda kebakaran meliputi kenaikan suhu, kemunculan titik api, peningkatan gas-gas (NO, CO₂, CO, CH₄, VOC, Benzena, dan SO), peningkatan konsentrasi partikel asap dengan median diameter 2.5-10 mikrometer (PM_{3.5} – PM₁₀) [3], menurunnya kelembapan, dan terdapatnya titik api. Selama ini, penanganan kebakaran hutan umumnya dilakukan secara manual yaitu dengan menggunakan teropong, menara pemantau, dan patroli darat. Keterbatasan sumber daya manusia dan peralatan yang memadai serta berat dan luasnya medan menyebabkan tanda-tanda awal kebakaran hutan relatif sulit dideteksi. Sedangkan penggunaan citra satelit [4] membutuhkan biaya tinggi, tenaga ahli, kurang dapat mendeteksi fase terjadinya asap (*smouldering*) [5], tundaan deteksi yang sangat lama [4]. Disamping itu, deteksi panas terkadang tidak dapat dilakukan ketika tertutup awan dan dibutuhkan cakupan area kebakaran yang luas agar dapat diketahui kebakaran tersebut [6]. Metode lain dengan menggunakan *Wireless Sensor Network* (WSN) yang secara kuantitatif digunakan untuk deteksi dini kebakaran hutan. Namun, untuk area hutan yang sangat luas tentunya diperlukan sistem yang kompleks dan biaya perawatan tinggi seperti tower sebagai sarana berkomunikasi [4].

Foto udara dengan melibatkan pesawat ringan atau bahkan helikopter juga dapat digunakan untuk deteksi kebakaran hutan. Namun, metode ini kurang memungkinkan untuk digunakan setiap saat karena kebakaran hutan relatif sulit diprediksi dan mengingat mahal biaya serta dibutuhkannya seorang yang ahli dalam mengoperasikan peralatan tersebut. Metode lain yang tengah marak dikembangkan adalah menggunakan *Unmanned Aerial Vehicle* (UAV) dengan meletakkan sistem detektor sebagai muatan (*payload*). Keterbatasan sistem kapasitas catu daya baterai yang digunakan pada UAV membuat muatan yang dibawa harus ditekan sekecil mungkin (terbatas, ringan dan spesifik) untuk mencapai operasi waktu yang lama [7] sesuai dengan misinya. Padahal untuk mendapatkan informasi yang lengkap yang dibutuhkan sensor (data) yang lengkap pula (lebih kompleks) [8]. Dengan adanya sensor yang bersifat kualitatif maka dapat mengurangi adanya jumlah kompleksitas sistem tanpa mengurangi adanya informasi yang besar dibanding dengan sensor dengan sifat kuantitatif. Sensor yang bersifat kualitatif menjadi alternatif dalam membangun sistem detektor cerdas sebagai *payload*. Sistem tersebut dapat melakukan keputusan berdasarkan data kualitatif yang diolah dengan mesin pengenalan pola dalam mengidentifikasi tanda awal kebakaran hutan.

Electronic nose (e-nose) adalah sebuah instrumen berbasis larik sensor gas kimia yang dapat mentransformasi gas volatil dalam bentuk senyawa atau unsur menjadi sinyal listrik [9]. Transformasi dari aroma menjadi sinyal listrik yang dihasilkan oleh masing-masing sensor mempunyai ciri spesifik yang dapat digunakan oleh mesin pengenalan pola. Implementasi instrumen cerdas ini telah banyak dilakukan di berbagai bidang seperti kosmetik [10], bioteknologi [11], pengobatan [12], perlindungan lingkungan [13] serta pengolahan makanan [14] dan minuman [15]. E-nose di bidang lingkungan seperti dilakukan [16] difungsikan untuk mendeteksi limbah cair berbahaya atau tidak [16] dan [17] dapat mengklasifikasi dengan *Principal Component Analysis* (PCA) hingga 95,5% asap kebakaran gambut dengan non gambut menggunakan 5 sensor gas. Simulasi deteksi kebakaran hutan gambut dan non gambut untuk satu titik api dengan e-nose sebagai *payload* UAV menggunakan K-Nearest Neighbour (K-NN) dapat mengklasifikasi jenis kebakaran tersebut hingga 86,1% [18].

E-nose sebagai detektor kebakaran hutan yang dilakukan oleh [18] masih terbatas untuk luas area yang kecil dan hanya dapat digunakan mendeteksi asap dalam satu titik api dengan mengabaikan faktor angin dan kecepatan pesawat. Sedangkan tanda-tanda kebakaran hutan tidak hanya berdasarkan asap yang ditimbulkan, namun juga ditentukan oleh banyaknya titik api yang muncul [4], kelembapan yang menurun karena konsentrasi CO₂ dan suhu meningkat [19] serta adanya partikel debu yang berukuran 2,5 pm (PM-2.5) – 10 pm (PM-10). Data masukan yang diperoleh dari gabungan beberapa detektor ini selanjutnya dianalisis dengan metode pengenalan pola yang dapat mengidentifikasi kebakaran hutan tersebut. Beberapa metode pengenalan pola telah banyak diterapkan seperti [20] untuk mendeteksi kebakaran rumah dan [13] untuk mengklasifikasi asap dari kebakaran rumah tangga. Metode JST BP (*backpropagation*) memiliki kemampuan ketahanan yang baik, korelasi yang kuat, residu yang kecil, serta rating klasifikasi yang tinggi pada pengaplikasian e-nose di bidang lingkungan [21] [22]. Selain itu, JST BP memiliki kemampuan di dalam menggabungkan beberapa parameter yang berbeda seperti Tian [23] menggabungkan masukan JST Propagasibalik dengan data e-nose serta e-tongue dan menghasilkan hasil 100% dari pada metode yang lain. Berdasarkan kelebihan-kelebihan metode tersebut maka sebuah sistem detektor kebakaran hutan cerdas diperlukan untuk mengidentifikasi secara dini tanda-tanda kebakaran hutan.


2. METODE PENELITIAN

2.1 Bahan

Bahan yang digunakan dalam penelitian ini adalah sampel isi hutan berupa kayu, pepohonan hidup dan kering, daun basah dan kering, gambut, rumput basah dan kering, serta tanah kering [4] sebagai suatu mini model hutan yang terbakar. Bahan-bahan tersebut menjadi sumber asap sampel kebakaran dengan adanya penambahan asap sampel kebakaran dari plastik. Jadi bahan yang digunakan pada penelitian ini berupa kayu (pepohonan hidup dan kering), daun (basah dan kering), plastik, dan gambut yang dibakar dan diambil sampel asapnya.

2.2 Sistem Detektor

Sistem detektor pada penelitian menggunakan 6 buah komponen utama dalam melakukan pendeteksian kebakaran hutan seperti pada Gambar 1. Enam buah komponen utama tersebut yaitu larik sensor (e-nose), sensor suhu, sensor kelembapan, sensor debu, GPS, dan sensor FLIR. E-nose menggunakan beberapa sensor gas yang digunakan dalam penelitian ini yaitu MiCS 814, MQ 7, MQ 9, MQ 135, dan TGS 2600, sensor suhu dan kelembapan menggunakan DHT 11, sensor debu menggunakan GP2Y1010AU0F, GPS menggunakan m8n, dan FLIR menggunakan AMG 8833. Data sensor yang dibaca dan diolah oleh mikrokontroller kemudian ditransmisikan menggunakan telemetri ke GCS (*Ground Control System*). Mikrokontroller yang digunakan dalam penelitian Teensy 3.2.



Gambar 1 Blok diagram sistem detektor

2.3 Pengambilan Data


Pengambilan data dilakukan dengan menempatkan sistem detektor tersebut menjadi *payload* untuk UAV. Peletakan sebagai *payload* dapat dilihat pada Gambar 2 yaitu terletak di bawah UAV dengan bentuk kotak. Selain itu, telemetri juga terpasang di bawah UAV dan belakang *sistem detektor*. UAV yang digunakan pada penelitian ini yaitu menggunakan quadcopter. UAV pada penelitian ini hanya sebagai media dalam pengambilan data sampel asap kebakaran secara aerial. Pengambilan data dilakukan dengan melewati UAV di atas sampel pembakaran yang dibakar di dalam tong. Pengambilan data dilakukan dengan keempat jenis sampel ditambah dengan udara bersih (tidak adanya kebakaran). Data yang diperoleh e-nose, sensor suhu, kelembapan, debu, GPS, dan sensor FLIR kemudian dikirim ke GCS dengan telemetri dan diterima dengan format CSV (*Comma Separated Value*). Data yang diterima tersebut akan dilakukan proses pra-pemrosesan data.



Gambar 2 Desain Penempatan Perangkat Keras

2.4 Pra-pemrosesan Sinyal

Pra-pemrosesan data dilakukan sebelum dilakukan proses pengenalan oleh algoritme kecerdasan buatan dan pengenalan pola yaitu JST BP. Pra-pemrosesan data dilakukan untuk mempersiapkan data untuk dijadikan masukan untuk proses pengenalan proses dan kecerdasan buatan. Proses untuk mempersiapkan untuk ke proses pengenalan pola dan kecerdasan buatan yaitu *preprocessing signal* atau prapemrosesan sinyal. Maka dari itu, prapemrosesan data merupakan bagian awal dari proses komputasi. Pada penelitian ini proses prapemrosesan terdiri dari dua bagian yaitu proses pemotongan dan normalisasi seperti pada Gambar 3. Data dari lapangan yang masih terdiri beberapa data asap sampel kebakaran masuk pada bagian pemotongan data dan selanjutnya masuk dalam proses normalisasi *baseline*.



Gambar 3 Diagram alur proses pra-pemrosesan sinyal

2.4.1 Pemotongan Data

Proses pemotongan data dilakukan pada awal proses pra-pemrosesan sinyal dilakukan untuk memisahkan beberapa data yang diambil dari lapangan yang masih terdapat beberapa data asap sampel menjadi satu data asap sampel saja. Seperti pada Gambar 4a bahwa dalam sekali pengambilan data terdapat lebih dari 1 data yang ditunjukkan adanya 2 puncak untuk tiap respon sensor gas. Oleh karena itu, untuk memudahkan dilakukan pelatihan data nantinya maka pemotongan data ini harus dilakukan. Hasil pemotongan data pada Gambar 4a dapat dilihat pada Gambar 4b. Pada Gambar 4b terlihat hanya ada 1 puncak yang menunjukkan hanya ada 1 data pada gambar tersebut. Selain memotong beberapa data menjadi 1 data, proses pemotongan ini membuang data yang tidak dibutuhkan pada proses selanjutnya. Data yang tidak dibutuhkan yaitu data udara bersih yang tidak perlu banyak dimasukkan dalam hasil pemotongan data. Data bersih

dibutuhkan 1 atau 2 data di awal untuk mengetahui nilai *baseline* pada waktu pengambilan data dikarenakan setiap pengambilan data akan berbeda pula nilai *baseline*-nya. Terlihat pada Gambar 4b data udara bersih antara dua buah puncak tidak dimasukkan kedalam hasil pemotongan dan hanya diambil 1-2 buah data di awal saja. Setelah proses pemotongan data ini telah selesai dilakukan maka dapat dilakukan proses selanjutnya yaitu proses normalisasi *baseline*.




(a)
(b)
Gambar 4 (a) Data mentah larik sensor dari lapangan, (b) Hasil pemotongan data mentah larik sensor

2.4.2 Normalisasi Baseline

Proses normalisasi baseline dilakukan setelah dilakukan pemotongan data dan sebelum data dilakukan ekstraksi ciri. Proses normalisasi baseline dilakukan dengan tujuan untuk mengurangi derau tambahan (δ_A) yang terdapat pada sinyal yang dihasilkan oleh sensor gas. Proses normalisasi baseline ini menggunakan metode differensial. Metode differensial merupakan metode normalisasi baseline dengan mengurangi respon sinyal (x) dengan nilai *baseline*-nya (x_0) seperti pada persamaan 1 [24]. Nilai *baseline* diambil pada nilai awal sebelum terjadinya kenaikan nilai akibat respon dari asap pembakaran sampel. Seperti pada Gambar 4b terdapat beberapa data yang cenderung stabil yang akan dijadikan sebagai nilai *baseline* dari tiap sensor yaitu pada data awal. Data awal yang stabil tersebut merupakan data udara bersih sebelum UAV melewati asap sampel pembakaran.

$$x_{dif} = (x + \delta_A) - (x_0 + \delta_A) = x - x_0 \quad (1)$$

Pada Gambar 5 merupakan hasil normalisasi *baseline* dari data pada Gambar 4b dengan metode differensial. Pada gambar tersebut dapat dilihat bahwa semua nilai *baseline* sensor yang sebelumnya sensor MiCS 6814 CO memiliki baseline 0,72 V, MiCS 6814 NO₂ memiliki baseline 0,36 V, MQ7 memiliki baseline 1,01 V, MQ9 memiliki baseline 0,16 V, MQ135 memiliki baseline 2,03 V, dan TGS2600 memiliki baseline 1,11 V setelah dilakukan normalisasi berada pada satu nilai yaitu 0 ditunjukkan data tersebut bermula pada nilai 0. Dari data yang telah dilakukan normalisasi *baseline* terlihat bahwa lebih mudah untuk dilakukan identifikasi respon sensor dibanding dengan data yang belum dilakukan normalisasi *baseline*.



Gambar 5 Hasil normalisasi *baseline*


2.5 Ekstraksi Ciri

Proses ekstraksi ciri merupakan proses yang sangat penting dalam proses mempersiapkan data untuk dilakukan pengenalan pola. Proses ekstraksi merupakan proses reduksi data yang berupa sinyal seperti Gambar 5 menjadi sebuah data yang relevan terhadap informasi yang terkandung dalam data yang akan diekstraksi cirinya. Ekstraksi ciri bertujuan untuk mengetahui pola-pola dari masing-masing asap pembakaran sampel. Ekstraksi ciri pada penelitian ini dilakukan terhadap 6 buah sensor pada larik sensor, sensor suhu, kelembapan, debu, dan FLIR. Pada ekstraksi ciri pada larik sensor ciri yang digunakan yaitu maksimal, *difference*, integral, dan rata-rata seperti pada penelitian tentang ekstraksi ciri pada enose [25]. Keempat ciri tersebut diimplementasikan untuk memilih ciri yang sesuai dengan data pada penelitian ini. Ciri maksimum merupakan ekstraksi ciri dengan mengambil nilai maksimum di setiap respon sensor. Ciri intergral adalah mengambil ciri dengan menghitung luasan pada waktu tertentu atau respon tertentu. Ciri *average* merupakan nilai rata-rata data ketika terjadi kenaikan sampai turun kembali. Ciri *average* merupakan nilai rata-rata data ketika terjadi kenaikan sampai turun kembali. Ciri *difference* merupakan ciri yang sangat umum dilakukan yaitu dengan menghitung selisih antara titik maksimum dengan titik mula sensor merespon gas.

Pada ekstraksi ciri selain sensor gas, ekstraksi ciri sensor lainnya menggunakan nilai maksimum atau minimum sesuai dengan karakteristik atau ciri dari respon sensor terhadap adanya sebuah asap kebakaran. Pada data sensor suhu, kebakaran terjadi menyebabkan suhu meningkat sehingga ekstraksi ciri pada data sensor suhu dengan menggunakan nilai maksimum. Sebaliknya, pada data sensor kelembapan akan terjadinya penurunan ketika adanya kebakaran maka data sensor kelembapan menggunakan ekstraksi ciri minimum. Data sensor debu menggunakan ekstraksi maksimum dikarenakan ketika terjadinya kebakaran menyebabkan kepadatan debu semakin tinggi. Begitupula data sensor FLIR, terjadinya kebakaran tentunya menaikkan suhu hasil pembacaan sensor FLIR terhadap suhu sekitar yang diamati sehingga menggunakan ciri maksimum merupakan ciri yang digunakan dalam ekstraksi data sensor FLIR ini.


2.6 Pelatihan dan Pengujian BP

Proses klasifikasi dan identifikasi dilakukan dengan menggunakan metode Jaringan Syaraf Tiruan propagasi balik atau *backpropagation* (JST BP). Proses model JST BP untuk dapat melakukan identifikasi untuk beberapa titik api melalui proses beberapa tahapan seperti pada Gambar 6. Pada seluruh proses pelatihan menggunakan konfigurasi model awal JST BP seperti pada Gambar 7. Pada gambar model pelatihan awal JST BP menggunakan formasi 10-2-5. Formasi 10-2-5 merupakan 10 node pada *layer* masukan, 2 node pada *hidden layer*, dan 5 node pada *layer* keluaran. Formasi tersebut dapat dilihat juga hanya memiliki 1 buah *hidden layer* yang digunakan. Fungsi aktivasi yang digunakan pada model penelitian ini yaitu Rectified Linear Unit (ReLU) dan Softmax. Fungsi aktivasi ReLU digunakan pada lapisan masukan (input layer) serta tersembunyi (hidden layer) dan fungsi aktivasi softmax digunakan pada lapisan keluaran (output layer). Nilai bobot semua node dipilih secara acak dan semua bias bernilai 0.



Gambar 6 Flowchart JST Backpropagation

Tahap pertama pelatihan menggunakan semua sensor dengan 4 buah ciri yang berbeda. Pada tahap pertama ini memiliki keluaran berupa 4 model hasil pelatihan dengan setiap modelnya menggunakan ekstraksi ciri yang berbeda. Proses pelatihan ini menggunakan data sebanyak 550 data dengan 5 buah sampel yang berbeda. Pada proses ini menghasilkan nilai akurasi dan nilai *loss* pada masing-masing model tersebut. Pada tahap kedua hampir sama dengan pada tahap satu hanya saja pelatihan tersebut hanya menggunakan data dari e-nose dan model dengan masukan 6 node. Pada tahap kedua ini menghasilkan 4 buah model juga yang akan memiliki keluaran berupa nilai akurasi dan *loss*. Hasil akurasi pada tahap 1 dan tahap 2 dibandingkan untuk setiap modelnya untuk ke tahap selanjutnya melakukan pengujian. Proses pengujian dilakukan dengan 4 ciri yang telah dipilih pada model sebelumnya (pada saat pelatihan). Proses pengujian ini akan menghasilkan 4 buah model pula. Empat model tersebut akan menghasilkan nilai akurasi dan *loss*. Model yang terbaik akan dipilih untuk dilakukan pengujian untuk identifikasi beberapa titik api dan akan menghasilkan nilai akurasi dan *loss*.



Gambar 7 Model awal JST-BP

3. HASIL DAN PEMBAHASAN

3.1 Hasil Pelatihan dengan Menggunakan Seluruh Sensor

Proses pelatihan menggunakan seluruh sensor, maka sensor yang digunakan yaitu 6 sensor gas, sensor suhu, temperatur, sensor debu, dan sensor FLIR. Sensor-sensor tersebut keseluruhan berjumlah 10 sensor yang merupakan jumlah masukan dari model pada tahap ini. Proses pelatihan menggunakan data sebanyak 550 buah data dengan 110 buah data merupakan data udara bersih, 110 buah data asap pembakaran plastik, 110 buah data asap pembakaran kayu, 110 buah data asap pembakaran kayu, 110 buah data asap pembakaran daun, dan 110 buah data asap pembakaran gambut. Data tersebut sebagai masukan proses pra-pelatihan dan pelatihan. Proses pra-pelatihan bertujuan untuk melakukan penalaan *hyperparameter* model pelatihan. Setelah didapat *hyperparameter* yang sesuai maka dilakukan proses pelatihan. Proses pelatihan pada tahap ini untuk menyesuaikan bobot agar dapat mengidentifikasi dengan baik. Pada proses pelatihan ini memiliki epoch sebanyak 150. Hasil proses pelatihan dapat dilihat pada Tabel 1. Terlihat bahwa model dengan ciri maksimum memiliki nilai akurasi terbesar dan nilai *loss* paling kecil yaitu 98,38% dan 0,0070. Setelah itu model dengan ciri *difference* dengan akurasi 98,20% dan *loss* 0,0097, dan model dengan ciri *average* 97,58% dan *loss* 0,0172, dan model dengan ciri integral memiliki akurasi 97,58% dan *loss* 0,0096.

Tabel 1 Hasil akurasi dan nilai *loss* pada evaluasi model

No	Model	Akurasi	Loss
1	Model ciri maksimum	98,38%	0,0070
2	Model ciri <i>difference</i>	98,18%	0,0097
3	Model ciri <i>average</i>	97,58%	0,0172
4	Model ciri integral	97,58%	0,0096

3.2 Hasil Pelatihan dengan Menggunakan Masukan Data E-nose

Proses pelatihan menggunakan data e-nose saja sebagai masukan model. Dengan masukan e-nose saja maka formasi untuk model awal pelatihan ini yaitu 6-2-5. Data yang digunakan untuk pelatihan juga sejumlah 550 data dengan 110 buah data merupakan data udara bersih, 110 buah data asap pembakaran plastik, 110 buah data asap pembakaran kayu, 110 buah data asap pembakaran kayu, 110 buah data asap pembakaran daun, dan 110 buah data asap pembakaran gambut. Sama seperti proses sebelumnya proses pelatihan ini terdapat proses penalaan *hyperparameter*. Setelah model telah ditala dengan data yang sama maka proses pelatihan dilakukan untuk menyesuaikan bobot node supaya dapat mengidentifikasi asap dengan baik. Hasil evaluasi pelatihan dari proses ini seperti terlihat pada Tabel 2. Pada proses ini, model dengan ciri *difference* memiliki performa terbaik dibandingkan dengan model ekstraksi yang lain. Model dengan ekstraksi *difference* memiliki akurasi 95,35% dengan *loss* 0,0435, model model dengan ciri maksimum memiliki akurasi 95,15% dan *loss* 0,0196, model model dengan ciri *average* memiliki akurasi 87,68% dan *loss* 0,0431, serta metode dengan ciri integral memiliki akurasi 82,62% dan *loss* 0,0584.

Tabel 2 Hasil akurasi dan nilai *loss* pada evaluasi model dengan masukan data e-nose

No	Model	Akurasi	Loss
1	Model ciri maksimum	95,15%	0,0196
2	Model ciri <i>difference</i>	95,35%	0,0435
3	Model ciri <i>average</i>	87,68%	0,0431
4	Model ciri integral	82,62%	0,0584

Hasil pelatihan proses ini dibandingkan dengan metode pelatihan dengan seluruh sensor terdapat perbedaan. Pada hasil pelatihan dengan menggunakan sensor lengkap memiliki akurasi lebih tinggi dibanding dengan akurasi pada pelatihan tanpa sensor selain e-nose. Pada hasil ekstraksi maksimum memiliki perbedaan akurasi 3,23% dan *loss* 0,0126, ekstraksi *difference* memiliki perbedaan akurasi 2,85% dan *loss* 0,0338, ekstraksi *average* memiliki perbedaan akurasi 9,90% dan *loss* 0,0259, dan ekstraksi inetgral memiliki perbedaan akurasi 14,96% dan *loss* 0,0488. Dari perbedaan-perbedaan tersebut dapat dilihat bahwa akurasi mengalami peningkatan ketika masukan pelatihan ditambah dengan sensor suhu, kelembapan, debu, dan FLIR. Dengan demikian bahwa model dengan sensor tambahan tersebut dipilih untuk tahap selanjutnya yaitu pengujian.

3.3 Hasil Pengujian Model Terpilih

Pengujian dilakukan dengan model terpilih yaitu model dengan menggunakan sensor tambahan. Pengujian ini juga menggunakan 4 model yang berbeda dengan model dengan ciri ekstraksi berbeda. Proses pengujian ini menggunakan data sebanyak 100 data dengan data yang belum pernah dilakukan pelatihan. Hasil pengujian dapat dilihat pada Tabel 3. Pada pengujian model dengan ekstraksi maksimum memiliki akurasi 98% dan *loss* 0,0078, model dengan ciri ekstraksi *difference* memiliki akurasi 91% dan *loss* 0,0258, model dengan ciri ekstraksi *average* memiliki akurasi 40%, 0,2080, serta model dengan ciri ekstraksi integral dengan akurasi 28% dan *loss* 0,2835. Dari hasil tersebut bahwa model dengan ciri ekstraksi memiliki performa yang lebih baik baik pada saat pelatihan serta pengujian daripada model yang lain, maka model dengan ciri ekstraksi maksimum dipilih untuk dilakukan pengujian pada beberapa titik.

Tabel 3 Hasil pengujian 4 model dengan ekstraksi berbeda

No	Model	Akurasi	Loss
1	Model ciri maksimum	98%	0,0078
2	Model ciri <i>difference</i>	91%	0,0258
3	Model ciri <i>average</i>	40%	0,2080
4	Model ciri integral	28%	0,2835

3.4 Hasil Pengujian Model Terpilih pada Beberapa Titik Api

Pengujian model yang terpilih yaitu model dengan ciri maksimum kemudian dilakukan pengujian terhadap data beberapa titik api dengan sampel asap yang berbeda. Pada pengujian ini terdiri dari 50 kali data dengan tiap data terdapat 3 titik api sehingga total memiliki 150 titik api. Hasil pengujian mendapatkan akurasi 100% dalam memprediksi data dengan beberapa titik api. Terlihat pada Tabel 4 bahwa bahwa nilai aktual dan prediksi bernilai sama. Begitu pula data yang lain yaitu plastik dengan 22 data, kayu dengan 37 data, daun dengan 46 data, dan gambut dengan 45 data memiliki jumlah yang sama antara prediksi dan aktual yang menunjukkan bahwa akurasi pengindentifikasian jenis asap sampel kebakaran bernilai 100%.

Tabel 4 *Confusion Matrix* pengujian model dengan beberapa titik api

		Prediksi			
		Plastik	Kayu	Daun	Gambut
Aktual	Plastik	22	0	0	0
	Kayu	0	37	0	0
	Daun	0	0	46	0
	Gambut	0	0	0	45

4. KESIMPULAN

Berdasarkan pengujian, pengamatan, dan analisis hasil penelitian yang telah diperoleh, maka didapatkan kesimpulan dari penelitian ini identifikasi asap beserta titik-titik api dengan e-nose sebagai payload dapat dilakukan dengan menggunakan JST-BP dengan menggabungkan beberapa sensor tidak hanya e-nose, 2. Penggabungan e-nose dengan sensor DHT11, debu, dan FLIR dapat meningkatkan akurasi model, keempat model tersebut yang dipakai meunjukkan

bahwa model dengan ciri maksimum lebih baik daripada keempat model yang lain, dan terbukti bahwa model JST-BP dapat secara baik melakukan identifikasi asap untuk 1titik api dengan akurasi 98% dan beberapa titik api dengan akurasi 100%.

5. SARAN

Saran-saran yang disampaikan untuk pengembangan penelitian selanjutnya yaitu penggunaan FLIR digunakan dengan FLIR yang lebih baik lagi agar jangkuan pengambilan data lebih tinggi, dan sampel asap pembakaran diperbanyak lebih dari 5 jenis sampel seperti penambahan asap karet, kertas, dan lain-lain.

DAFTAR PUSTAKA

- [1] KKLH, *Status Hutan dan Kehutanan Indonesia 2018*. 2018.
- [2] BNBP, "Rekapitulasi Luas Kebakaran Hutan dan Lahan (Ha) Per Provinsi Di Indonesia Tahun 2014-2019," *Karhutla Monit. Sist.*, no. 1, hal. 26–27, 2019.
- [3] T. V Larson dan J. Q. Koenig, "Wood Smoke : Emissions," *Combustion*, 1994.
- [4] A. A. A. Alkhatib, "A review on forest fire detection techniques," *Int. J. Distrib. Sens. Networks*, vol. 2014, 2014.
- [5] D. Madsen, H. A. Azeem, M. Sandahl, P. van Hees, dan B. Husted, "Levoglucosan as a Tracer for Smouldering Fire," *Fire Technol.*, vol. 54, no. 6, hal. 1871–1885, 2018.
- [6] R. B. Edwards, R. L. Naylor, M. M. Higgins, dan W. P. Falcon, "Causes of Indonesia's forest fires," *World Dev.*, vol. 127, 2020.
- [7] K. Klausen, T. I. Fossen, T. A. Johansen, dan A. P. Aguiar, "Cooperative path-following for multirotor UAVs with a suspended payload," *2015 IEEE Conf. Control Appl. CCA 2015 - Proc.*, hal. 1354–1360, 2015.
- [8] D. Roggen *dkk.*, "Collecting complex activity datasets in highly rich networked sensor environments," *INSS 2010 - 7th Int. Conf. Networked Sens. Syst.*, hal. 233–240, 2010.
- [9] D. Lelono, K. Triyana, S. Hartati, dan J. E. Istiyanto, "Development of electronic nose with highly stable sample heater to classify quality levels of local black tea," *Int. J. Adv. Sci. Eng. Inf. Technol.*, vol. 7, no. 2, hal. 352–358, 2017.
- [10] T. Eamsa-Ard, M. M. Swe, T. Seesaard, dan T. Kerdcharoen, "Development of Electronic Nose for Evaluation of Fragrance and Human Body Odor in the Cosmetic Industry," *2018 IEEE 7th Glob. Conf. Consum. Electron. GCCE 2018*, no. December, hal. 592–593, 2018.
- [11] K. Nayak dan V. Nayak, "E-Nose System to Detect E-Coli in Drinking Water of Udupi District," *Int. J. Eng. Res. Dev.*, vol. 1, no. 12, hal. 2278–67, 2012.
- [12] D. Li, T. Lei, S. Zhang, X. Shao, dan C. Xie, "A novel headspace integrated E-nose and its application in discrimination of Chinese medical herbs," *Sensors Actuators, B Chem.*, vol. 221, hal. 556–563, 2015.
- [13] S. Sadeghifard, M. Anjomshoa, dan E. Esfandiari, "A new embedded E-nose system in smoke detection," *2011 1st Int. eConference Comput. Knowl. Eng. ICCKE 2011*, hal. 18–21, 2011.
- [14] A. Amari, N. El Barbri, E. Llobet, N. El Bari, X. Correig, dan B. Bouchikhi, "Monitoring the freshness of Moroccan Sardines with a neural-network based electronic nose," *Sensors*, vol. 6, no. 10, hal. 1209–1223, 2006.
- [15] M. B. Banerjee, R. B. Roy, B. Tudu, R. Bandyopadhyay, dan N. Bhattacharyya, "Black tea classification employing feature fusion of E-Nose and E-Tongue responses," *J. Food Eng.*, vol. 244, no. June 2018, hal. 55–63, 2019.
- [16] M. Moufid, M. Hofmann, N. El, C. Tiebe, M. Bartholmai, dan B. Bouchikhi, "Talanta Wastewater monitoring by means of e-nose , VE-tongue , TD-GC-MS , and," *Talanta*, vol. 221, no. July 2020, hal. 121450, 2020. Riyanto, D. Lelono, dan T. W. Supardi, "Rancang Bangun Electronic Nose untuk Mendeteksi Kebakaran Gambut," 2017.