

Diagnosis Kanker Paru-paru Berbasis Data Klinis: Evaluasi Performa Algoritma Pembelajaran Mesin

Riska Kurnia Septiani¹, Zulfati Dinul Fatiha^{2*}, Dicky Octaviano³

¹Fakultas Teknologi Informasi, Universitas Nusa Mandiri, Jakarta, Indonesia

^{2,3}Facultas Ekonomi dan Bisnis, Universitas Bina Sarana Informatika, Jakarta, Indonesia

Email: ¹14220021@nusamandiri.ac.id, ²zulfati.zdf@bsi.ac.id, ³dicky.doc@bsi.ac.id

Penulis korespondensi*

(received: 20-02-26, revised: 02-03-26, accepted: 30-04-26)

Abstrak

Kanker paru-paru adalah salah satu penyakit paling mematikan di dunia, menyebabkan lebih dari 1,76 juta kematian setiap tahunnya menurut WHO pada tahun 2020. Deteksi dini menjadi krusial dalam meningkatkan prognosis pasien, namun sering kali menantang karena gejala awal yang tidak spesifik. Dalam beberapa tahun terakhir, teknologi medis dan komputasi telah menghadirkan peluang baru dengan memanfaatkan pembelajaran mesin, terutama deep learning, untuk meningkatkan diagnosa kanker paru-paru. Studi ini mengevaluasi beberapa algoritma *Machine Learning* seperti *K-Nearest Neighbors* (k-NN), *Logistic Regression*, *Naïve Bayes*, *Support Vector Machine* (SVM), dan *Neural Network* berdasarkan data klinis untuk memprediksi kanker paru-paru. Hasil evaluasi menunjukkan bahwa k-NN dan *Neural Network* memiliki performa terbaik dengan akurasi mencapai 0.92, sementara *Naïve Bayes* dan *Neural Network* menunjukkan presisi tertinggi untuk kelas kanker paru-paru (0.94). *Logistic Regression* dan SVM juga memberikan hasil yang baik, meskipun dengan variasi dalam presisi dan recall untuk kedua kelas. Penelitian ini memberikan wawasan penting untuk pengembangan sistem pendukung keputusan di bidang medis, dengan potensi untuk meningkatkan diagnosis dini, pengelolaan, dan prognosis kanker paru-paru secara efektif, serta mengurangi beban penyakit dan meningkatkan kualitas hidup pasien di masa depan. Implementasi pembelajaran mesin di sektor kesehatan menunjukkan bahwa teknologi ini dapat menjadi alat yang sangat berharga dalam mendeteksi dan mengelola penyakit serius seperti kanker paru-paru.

Kata Kunci: Kanker Paru-Paru, Pembelajaran Mesin, Jaringan Syaraf Tiruan

Abstract

Lung cancer is one of the deadliest diseases in the world, causing more than 1.76 million deaths each year according to WHO in 2020. Early detection is crucial in improving patient prognosis, but it is often challenging due to non-specific early symptoms. In recent years, medical and computational technology has presented new opportunities by utilizing machine learning, especially deep learning, to enhance lung cancer diagnosis. This study evaluates several machine learning algorithms such as K-Nearest Neighbors (k-NN), Logistic Regression, Naïve Bayes, Support Vector Machine (SVM), and Neural Network based on clinical data to predict lung cancer. The evaluation results show that k-NN and Neural Network have the best performance with an accuracy of up to 0.92, while Naïve Bayes and Neural Network show the highest precision for the lung cancer class (0.94). Logistic Regression and SVM also provide good results, although with variations in precision and recall for both classes. This research provides important insights for the development of decision support systems in the medical field, with the potential to effectively improve early diagnosis, management, and prognosis of lung cancer, thereby reducing the disease burden and improving patients' quality of life in the future. The implementation of machine learning in the healthcare sector shows that this technology can be a highly valuable tool in detecting and managing serious diseases such as lung cancer.

Keyword: Lung Cancer, Machine Learning, Neural Network

1. PENDAHULUAN

Paru-paru merupakan organ penting yang berperan dalam sistem pernapasan dan peredaran darah tubuh manusia [1]. Kanker paru-paru adalah salah satu penyakit yang paling mematikan di seluruh dunia, dengan tingkat kejadian yang terus meningkat secara signifikan. Menurut Organisasi Kesehatan Dunia (WHO), kanker paru-paru menyebabkan lebih dari 1,76 juta kematian setiap tahunnya pada tahun 2020 [2]. Deteksi dini sangat

penting dalam meningkatkan prognosis dan tingkat kelangsungan hidup pasien dengan kanker paru-paru. Diagnosa yang tepat waktu sering kali menjadi tantangan, karena gejala kanker paru-paru sering tidak spesifik pada tahap awal penyakit ini [3].

Kanker paru adalah jenis tumor ganas yang berasal dari epitel bronkus, yaitu sel-sel epitelium pada sistem pernapasan. Sel-sel kanker ini dapat menyebar dan bermetastasis ke organ lain, seperti otak. Penyebab utama kanker paru adalah kebiasaan merokok, di mana rokok mengandung zat karsinogen yang berbahaya. Faktor-faktor lain seperti pengaruh genetik, status imunologi, dan predisposisi akibat penyakit lain juga dapat menjadi penyebabnya. Deteksi kanker paru dapat dilakukan melalui *X-Ray*, *CT Scan*, *PET-CT Scan*, dan bronkoskopi [4], [5].

Dalam beberapa tahun terakhir, kemajuan teknologi medis dan komputasi telah membuka peluang baru untuk meningkatkan diagnosis kanker paru-paru menggunakan pembelajaran mesin. Teknik ini, terutama *deep learning*, menunjukkan potensi besar dalam menganalisis gambar medis dan mendeteksi pola-pola yang sulit dikenali secara manual [6]. Dengan memanfaatkan dataset yang besar dan beragam, model pembelajaran mesin dapat dilatih untuk mengenali tanda-tanda awal kanker paru-paru dengan tingkat akurasi yang tinggi. Model ini juga dapat mengurangi beban kerja tenaga medis dan meningkatkan efisiensi proses diagnosis [7].

Sejumlah penelitian telah mengaplikasikan berbagai algoritma pembelajaran mesin untuk deteksi dan prediksi kanker paru-paru. Shen et al. [8] menggunakan jaringan saraf convolutional (CNN) untuk menganalisis gambar CT scan, menghasilkan akurasi yang signifikan dalam deteksi nodul paru-paru yang mencurigakan. Studi lain oleh Wang [3] mengintegrasikan data klinis dengan data gambar untuk membangun model prediktif berbasis *deep learning*, yang memperlihatkan peningkatan dalam spesifisitas dan sensitivitas diagnosa dibandingkan metode konvensional. Teknik *deep learning*, seperti jaringan saraf dalam (DNN), juga telah berhasil diterapkan untuk analisis citra medis dalam konteks kanker paru-paru [4], [9]. Setio mengembangkan algoritma deteksi nodul *multiview* yang mampu mengurangi tingkat *false positive* secara signifikan [10].

Pendekatan terbaru dalam penelitian kanker paru-paru melibatkan integrasi berbagai jenis data medis. Esteva menggarisbawahi pentingnya data multimodal, seperti gabungan data klinis, genomik, dan citra medis, dalam meningkatkan performa model prediksi kanker paru-paru [11]. Penelitian lain oleh Hawkins mengembangkan model yang menggabungkan data *CT scan* dan biomarker untuk memperkirakan risiko kanker paru-paru pada populasi berisiko tinggi, menghasilkan prediksi yang lebih akurat dibandingkan model tunggal [12].

Namun demikian, penelitian-penelitian sebelumnya memiliki beberapa kelemahan yang perlu diatasi. Pertama, banyak studi yang hanya berfokus pada satu jenis algoritma atau pendekatan tanpa melakukan perbandingan komprehensif antar berbagai metode pembelajaran mesin [13]. Kedua, sebagian besar penelitian mengandalkan data gambar medis saja tanpa mempertimbangkan data klinis pasien yang dapat meningkatkan akurasi prediksi [14]. Ketiga, integrasi data multimodal yang melibatkan kombinasi berbagai jenis data medis masih jarang diterapkan secara efektif dalam model prediksi kanker paru-paru [15]. Keempat, beberapa studi tidak memberikan evaluasi menyeluruh menggunakan berbagai metrik performa seperti *precision*, *recall*, dan *F1-score*, yang penting untuk menilai kelayakan klinis model [16].

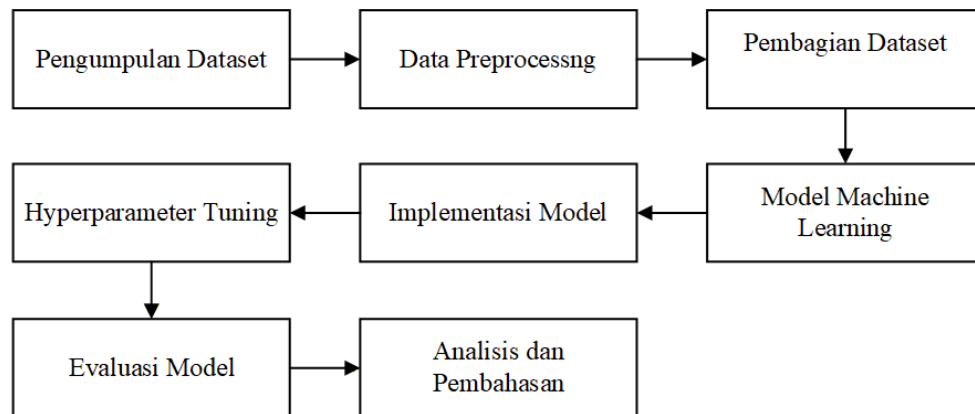
Penelitian ini bertujuan untuk mengembangkan dan mengevaluasi model prediksi kanker paru-paru berbasis pembelajaran mesin yang dapat membantu dalam deteksi dini dan prediksi risiko kanker paru-paru pada pasien. Model ini diharapkan dapat memanfaatkan berbagai jenis data medis, termasuk gambaran dari *CT scan thorax*, data klinis, dan faktor risiko pasien untuk menghasilkan prediksi yang akurat. Penelitian ini tidak hanya relevan dalam konteks pengembangan teknologi medis, tetapi juga memiliki potensi untuk memberikan dampak yang signifikan dalam praktek klinis sehari-hari [17].

Implementasi pembelajaran mesin di sektor kesehatan menunjukkan bahwa teknologi ini dapat menjadi alat yang sangat berharga dalam mendeteksi dan mengelola penyakit serius seperti kanker paru-paru. Penelitian ini memberikan wawasan penting untuk pengembangan sistem pendukung keputusan di bidang medis, dengan potensi untuk meningkatkan diagnosis dini, pengelolaan, dan prognosis kanker paru-paru secara efektif, serta mengurangi beban penyakit dan meningkatkan kualitas hidup pasien di masa depan [18]. Implementasi teknologi ini diharapkan dapat membuka jalan bagi inovasi baru dalam praktek medis, menyediakan solusi yang lebih presisi dan adaptif dalam menghadapi tantangan penyakit yang kompleks.

Penelitian ini mengembangkan model prediksi kanker paru-paru berbasis pembelajaran mesin dengan data medis variatif, seperti CT scan thorax dan data klinis, untuk meningkatkan akurasi deteksi dini. Meskipun banyak penelitian telah menggunakan algoritma seperti CNN dan Random Forest, penelitian ini menonjol melalui integrasi data multimodal. Dengan membandingkan berbagai algoritma, penelitian ini menunjukkan potensi signifikan pembelajaran mesin dalam praktik medis, khususnya dalam diagnosis, pengelolaan, dan prognosis kanker paru-paru, sehingga berkontribusi pada inovasi dalam teknologi medis.

2. METODOLOGI PENELITIAN

Bagian ini merinci tahapan-tahapan yang telah dilakukan untuk merancang dan melaksanakan penelitian, mulai dari pemilihan metode sampai analisis data. Tahapan penelitian ditunjukkan pada gambar 1.



Gambar 1. Tahapan Penelitian

2.1 Dataset dan Prapemrosesan Data

2.1.1 Pengumpulan Dataset

Penelitian ini menggunakan dataset kanker paru-paru yang diperoleh dari Kaggle, dengan jumlah 284 data dan 16 fitur. Dataset ini merupakan data klinis yang mencakup berbagai parameter medis pasien, seperti jenis kelamin, usia, status merokok, perubahan warna jari akibat kebiasaan merokok, tingkat kecemasan, pengaruh tekanan sosial, riwayat penyakit kronis, tingkat kelelahan, alergi, wheezing, konsumsi alkohol, batuk, sesak napas, kesulitan menelan, nyeri dada, serta variabel target berupa status kanker paru-paru. Dataset ini merepresentasikan pendekatan data klinis multiparameter yang digunakan untuk mendukung proses prediksi.

Tabel 1. Dataset

Atribut	Deskripsi
Gender	Jenis kelamin subjek, seperti pria atau wanita.
Age	Usia subjek pada saat studi atau pengumpulan data dilakukan.
Smoking	Status merokok subjek, misalnya apakah ia perokok atau bukan.
Yellow_Finger	Kemungkinan ada hubungan antara warna kuning pada jari dengan merokok berat.
Anxiety	Tingkat kecemasan subjek.
Peer_Pressure	Pengaruh tekanan dari teman sebaya terhadap perilaku merokok atau tidak merokok.
Chronic Disease	Kehadiran atau tidaknya penyakit kronis lain selain kanker paru-paru.
Fatigue	Tingkat kelelahan subjek.
Allergy	Kehadiran atau tidaknya riwayat alergi pada subjek.
Wheezing	Apakah subjek mengalami napas sengau atau tidak.
Alcohol	Pola konsumsi alkohol subjek.
Coughing	Frekuensi dan keparahan batuk yang dialami subjek.
Shortness of Breath	Apakah subjek mengalami sesak napas atau tidak.
Swallowing Difficulty	Apakah subjek mengalami kesulitan menelan atau tidak.
Chest pain	Apakah subjek mengalami nyeri dada atau tidak.
Lung Cancer	Variabel target utama yang ingin diprediksi atau dianalisis, misalnya apakah subjek memiliki kanker paru-paru atau tidak.

2.1.2 Data Preprocessing

Tahap prapemrosesan dilakukan untuk memastikan kualitas data sebelum digunakan dalam proses pemodelan. Proses ini mencakup beberapa langkah utama, yaitu pengecekan anomali data untuk memastikan tidak terdapat

nilai hilang atau data yang tidak konsisten. Selanjutnya, dilakukan transformasi fitur kategorikal dengan mengubah data kategorikal menjadi bentuk numerik menggunakan teknik *encoding* agar dapat diproses oleh algoritma pembelajaran mesin. Selain itu, normalisasi data dilakukan menggunakan metode *Min-Max Scaling* untuk menyamakan skala antar fitur, sehingga dapat meningkatkan stabilitas serta kinerja model dalam proses pembelajaran.

2.1.3 Pembagian Dataset

Setelah melalui tahap prapemrosesan, dataset dibagi menjadi tiga bagian, yaitu data latih, data uji, dan data validasi dengan rasio 60:20:20. Data latih digunakan untuk membangun model pembelajaran mesin, data validasi digunakan untuk proses penyetelan hyperparameter dan mengurangi overfitting, sedangkan data uji digunakan untuk mengevaluasi kinerja akhir model secara objektif.

2.2 Model Machine Learning

Bagian ini menjelaskan penggunaan berbagai model pembelajaran mesin untuk melakukan klasifikasi biner pada dataset *Lung Cancer*. Model-model ini mencakup algoritma tradisional seperti *Support Vector Machines* (SVM), *Logistic Regression*, *k-Nearest Neighbours* (k-NN), dan *Naive Bayes*, serta *Neural Network*. Evaluasi dilakukan terhadap setiap model untuk menilai kemampuannya dalam membedakan antara pasien dengan kanker paru-paru dan pasien normal.

2.2.1 K-Nearest Neighbor (KNN)

Algoritma *K-Nearest Neighbor* (KNN) merupakan metode klasifikasi yang menentukan kelas suatu objek berdasarkan kedekatan jarak terhadap data pembelajaran terdekat. Data diproyeksikan ke dalam ruang berdimensi banyak, di mana setiap dimensi merepresentasikan fitur dari data, sehingga memungkinkan proses pengukuran jarak antar objek. Salah satu metode yang umum digunakan untuk menghitung jarak adalah Euclidean Distance, sebagaimana dirumuskan pada Persamaan (1) [19].

$$d(x, x_i) = \sqrt{\sum_{j=1}^n (x_j - x_{(ij)})^2} \quad (1)$$

2.2.2 Naive Bayes Classifier

Naive Bayes classifier merupakan metode klasifikasi berbasis probabilitas yang mengacu pada Teorema Bayes. Konsep dasar metode ini pertama kali diperkenalkan oleh Thomas Bayes dan termasuk dalam model statistik bayesian sederhana. Istilah *naive* digunakan karena metode ini mengasumsikan bahwa setiap fitur bersifat independen satu sama lain (*class conditional independence*), meskipun dalam praktiknya asumsi tersebut tidak selalu terpenuhi [20]. Probabilitas posterior pada metode ini dihitung menggunakan Teorema Bayes sebagaimana dinyatakan pada Persamaan (2).

$$P(y|X) = \frac{P(y).P(x)}{P(y)} \quad (2)$$

2.2.3 Logistic Regression

Logistic Regression merupakan algoritma klasifikasi yang menggunakan distribusi Bernoulli untuk memodelkan variabel respon dalam bentuk kategori biner (0 dan 1), yang dipengaruhi oleh variabel prediktor dalam suatu model regresi [21]. Probabilitas suatu data termasuk ke dalam kelas tertentu dihitung menggunakan fungsi sigmoid, sebagaimana dirumuskan pada Persamaan (3).

$$P(y = 1|x) = \sigma(w \cdot x + b) \quad (3)$$
$$P(x) = 1 - \sigma(w \cdot x + b)$$

2.2.4 Support Vector Machine (SVM)


Support Vector Machine (SVM) adalah algoritma pembelajaran mesin yang digunakan untuk klasifikasi maupun prediksi. Prinsip kerja metode ini adalah mencari *hyperplane* atau ruang pemisah yang paling optimal untuk memisahkan data ke dalam kelas yang berbeda. Dalam praktiknya, data sering kali tidak dapat dipisahkan secara linear, yaitu kondisi ketika tidak terdapat garis atau bidang yang mampu memisahkan antar kelas secara

sempurna [22]. Fungsi keputusan SVM yang digunakan untuk menentukan kelas suatu data dinyatakan pada Persamaan (4).

$$f(x) = \text{sign}(w \cdot x + b) \quad (4)$$

2.2.5 Neural Network

Neural network, atau jaringan saraf tiruan, adalah metode komputasi yang meniru cara kerja jaringan saraf biologis [23]. Metode ini memanfaatkan elemen perhitungan *non-linear* yang disebut *neuron*, yang diorganisir dalam jaringan yang saling terhubung, mirip dengan jaringan saraf pada manusia. Jaringan saraf tiruan ini dirancang untuk memecahkan masalah tertentu, seperti pengenalan pola atau klasifikasi, melalui proses pembelajaran. *Neural network* terdiri dari lapisan input neuron (atau node, unit), satu atau lebih lapisan tersembunyi neuron, dan lapisan output *neuron*. Gambar 2 menunjukkan arsitektur *neural network*, termasuk garis-garis yang menghubungkan *neuron*. Setiap koneksi memiliki nilai numerik yang disebut bobot (*weight*).



Gambar 2. Arsitektur *Neural Network*

2.2.6 Confusion Matrix

Confusion matrix merupakan suatu metode untuk memberikan informasi hasil dari klasifikasi yang dilakukan oleh sistem yang berguna untuk menganalisis seberapa baik classifier mengenali tuple dari kelas yang berbeda. Sebagai contoh untuk *confusion matrix* dua kelas, maka akan di sebutkan menjadi kelas positif dan kelas negatif. True positif mengarah pada kelas positif yang diberi tanda dengan tepat oleh *classifier*, sementara true negatif adalah kelas negatif yang diberi tanda dengan tepat oleh *classifier*. False positif adalah kelas negatif yang diberi tanda dengan tidak tepat. False negatif adalah kelas positif yang diberi label dengan tidak tepat [22].

Metrik evaluasi yang digunakan dalam penelitian ini meliputi *accuracy*, *precision*, *recall*, dan *F1-score*. *F1-score* merupakan rata-rata harmonik (*harmonic mean*) dari *precision* dan *recall*, yang digunakan untuk memberikan keseimbangan antara kedua metrik tersebut, terutama pada kondisi data yang tidak seimbang. Perumusan *F1-score* dituliskan pada persamaan rumus 5.

$$F1 \text{ Score} = 2 \times \frac{\text{recall} \times \text{precision}}{\text{recall} + \text{precision}} \quad (5)$$

Precision adalah rasio observasi positif yang diprediksi dengan benar terhadap total observasi positif yang diprediksi. Perumusan *precision* dituliskan pada Persamaan (6) dan Persamaan (7).

$$Precision = \frac{\text{True Positive}}{\text{True Positive} + \text{False Positive}} \quad (6)$$

$$Precision = \frac{\text{True Positive}}{\text{Total Predicted Positive}} \quad (7)$$

Recall diartikan sebagai rasio hasil yang diprediksi dengan benar terhadap semua prediksi. Ini juga dikenal sebagai sensitivitas atau spesifisitas. Perumusan *recall* dituliskan pada Persamaan (8) dan Persamaan (9).

$$Recall = \frac{\text{True Positive}}{\text{True Positive} + \text{False Negative}} \quad (8)$$

$$Recall = \frac{True\ Positive}{Total\ Actual\ Positive} \quad (9)$$

Selanjutnya untuk melihat hasil yang baik dilihat dari tingkat keakuratannya. Akurasi adalah perbandingan prediksi yang benar dari seluruh prediksi yang dibuat oleh suatu algoritma. Hal ini dapat dihitung dengan membagi presisi dengan perolehan atau dengan 1 dikurangi tingkat negatif palsu (FNR) dibagi dengan tingkat positif palsu (FPR). Untuk menghitung akurasi, dapat dilihat pada Persamaan (10).

$$Accuracy = \frac{(TP+TN)}{(TP+FN+TN+FN)} \quad (10)$$

3. HASILDAN PEMBAHASAN

3.1 Akurasi *Machine Learnings*

Performa model *Machine Learning* pada tugas klasifikasi biner untuk kumpulan data Lung Cancer dirangkum pada Tabel 2 di bawah ini. Setiap model dievaluasi menggunakan metrik akurasi, presisi, *recall*, dan *F1-Score* untuk memberikan gambaran yang komprehensif tentang kinerja model. Akurasi adalah proporsi prediksi benar dari semua prediksi model, memberikan gambaran umum tentang seberapa sering model membuat keputusan yang tepat. Presisi adalah proporsi prediksi positif yang benar dari semua prediksi positif yang dibuat oleh model, menunjukkan bahwa model memiliki sedikit prediksi positif palsu, yang krusial dalam diagnosa penyakit serius di mana kesalahan positif dapat memiliki dampak besar.

Recall adalah proporsi kasus positif yang berhasil diidentifikasi dengan benar oleh model, penting terutama dalam deteksi kanker untuk menghindari melewatkan kasus positif yang krusial. *F1-Score* adalah harmonik rata-rata dari presisi dan *recall*, memberikan evaluasi kinerja yang seimbang pada model klasifikasi, terutama dalam menghadapi ketidakseimbangan kelas. Dengan menggabungkan kedua metrik tersebut, *F1-Score* memberikan gambaran yang lebih holistik tentang kinerja model dibandingkan dengan hanya menggunakan presisi atau *recall* saja.

Algoritma *K-Nearest Neighbors* (k-NN) mencapai akurasi 0,92 dalam klasifikasi kanker paru-paru, dengan presisi 0,92 untuk kasus kanker paru-paru dan 0,89 untuk kasus normal. *Recall* untuk kanker paru-paru adalah 0,98, menunjukkan kemampuan model dalam mendeteksi hampir semua kasus kanker. Kombinasi akurasi tinggi, presisi yang baik, dan *recall* yang tinggi menunjukkan bahwa k-NN efektif dalam mengidentifikasi kanker paru-paru tanpa melewatkan kasus positif, penting dalam konteks medis untuk diagnosis yang tepat dan penanganan yang cepat.

Tabel 2. Performa Model ML pada Tugas Klasifikasi Biner kumpulan data Lung Cancer

Metrik	k-NN	Logistic Regression	Naïve Bayes	SVM	Neural Network
Precision (0)	0.89	0.80	0.69	0.80	0.82
Precision (1)	0.92	0.92	0.94	0.92	0.94
Recall (0)	0.67	0.67	0.75	0.67	0.75
Recall (1)	0.98	0.96	0.92	0.96	0.96
F1-Score (0)	0.76	0.73	0.72	0.73	0.78
F1-Score (1)	0.95	0.94	0.93	0.94	0.95
Accuracy	0.92	0.90	0.89	0.90	0.92
Macro Avg (P)	0.91	0.86	0.82	0.86	0.88
Macro Avg (R)	0.82	0.81	0.83	0.81	0.85
Macro Avg (F1)	0.86	0.83	0.82	0.83	0.87
Weighted Avg (P)	0.92	0.90	0.89	0.90	0.92
Weighted Avg (R)	0.92	0.90	0.89	0.90	0.92
Weighted Avg (F1)	0.91	0.90	0.89	0.90	0.92
Support (0)	12	12	12	12	12
Support (1)	50	50	50	50	50

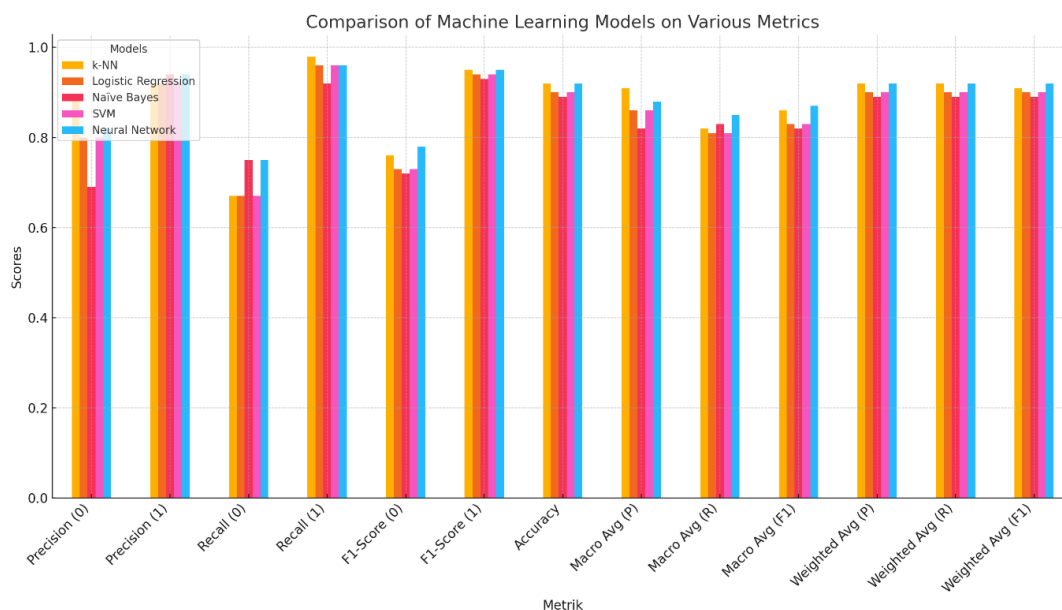
Algoritma *Logistic Regression* mencapai akurasi 0.90 dalam klasifikasi kanker paru-paru. Presisi untuk kelas kanker paru-paru adalah 0.92, menunjukkan bahwa 92% dari prediksi positif kanker paru-paru benar, sedangkan presisi untuk kelas normal adalah 0.80. *Recall* untuk kelas kanker paru-paru adalah 0.96, menandakan bahwa model berhasil mendeteksi 96% dari semua kasus kanker paru-paru yang sebenarnya. Dengan akurasi tinggi dan presisi yang baik, serta *recall* yang kuat untuk kelas kanker paru-paru, *Logistic*

Regression efektif dalam mengidentifikasi kanker paru-paru dengan sedikit kesalahan positif dan minim kegagalan dalam mendeteksi kasus positif yang sebenarnya.

Algoritma *Naive Bayes* mencapai akurasi 0.89 dalam klasifikasi kanker paru-paru. Presisi untuk kelas kanker paru-paru adalah 0.94, menunjukkan bahwa 94% dari prediksi positif kanker paru-paru adalah benar, sementara presisi untuk kelas normal adalah 0.69. *Recall* untuk kelas kanker paru-paru adalah 0.92, menandakan bahwa model berhasil mendeteksi 92% dari semua kasus kanker paru-paru yang sebenarnya. Dengan akurasi yang tinggi dan presisi yang baik untuk kelas kanker paru-paru, *Naive Bayes* efektif dalam mengidentifikasi kasus kanker dengan minim kesalahan, meskipun presisi untuk kelas normal sedikit lebih rendah, menunjukkan potensi untuk meningkatkan pengenalan kasus normal secara spesifik.

Algoritma *Support Vector Machine* (SVM) mencapai akurasi 0.90 dalam klasifikasi kanker paru-paru. Presisi untuk kelas kanker paru-paru adalah 0.92, menunjukkan bahwa 92% dari prediksi positif kanker paru-paru adalah benar, sedangkan presisi untuk kelas normal adalah 0.67. *Recall* untuk kelas kanker paru-paru mencapai 0.96, menandakan bahwa model berhasil mendeteksi 96% dari semua kasus kanker paru-paru yang sebenarnya. Dengan akurasi yang tinggi dan *recall* yang kuat untuk kelas kanker paru-paru, SVM efektif dalam mengidentifikasi kanker paru-paru dengan sedikit kesalahan positif, meskipun presisi untuk kelas normal memerlukan peningkatan untuk meningkatkan spesifikasinya.

Algoritma *Neural Network* mencapai akurasi 0.92 dalam klasifikasi kanker paru-paru. Presisi untuk kelas kanker paru-paru adalah 0.94, menunjukkan bahwa 94% dari prediksi positif kanker paru-paru adalah benar, sementara presisi untuk kelas normal adalah 0.82. *Recall* untuk kelas kanker paru-paru mencapai 0.96, menandakan bahwa model berhasil mendeteksi 96% dari semua kasus kanker paru-paru yang sebenarnya. Dengan akurasi tinggi dan presisi yang baik untuk kelas kanker paru-paru, *Neural Network* efektif dalam mengidentifikasi kanker dengan sedikit kesalahan positif, sementara presisi untuk kelas normal menunjukkan potensi untuk ditingkatkan dalam membedakan kasus normal secara spesifik.



Gambar 3. Performa Model ML pada Tugas Klasifikasi Biner kumpulan data Lung Cancer

Grafik pada Gambar 3 menunjukkan perbandingan visual dari performa kelima algoritma yang diuji. Dari grafik tersebut dapat diamati beberapa pola penting: Pertama, algoritma k-NN dan Neural Network secara konsisten menunjukkan performa terbaik di hampir semua metrik, dengan nilai akurasi, precision, recall, dan F1-score yang hampir setara. Kedua, Naive Bayes menunjukkan precision tertinggi untuk kelas kanker (0.94) namun memiliki precision terendah untuk kelas normal (0.69), mengindikasikan trade-off antara kemampuan mendeteksi kanker dan mengidentifikasi kasus normal. Ketiga, SVM dan Logistic Regression menunjukkan performa yang serupa dengan akurasi 0.90, namun keduanya memiliki precision kelas normal yang relatif rendah (0.67 dan 0.80). Keempat, recall untuk kelas kanker sangat tinggi di semua model (0.92-0.98), yang merupakan karakteristik penting untuk aplikasi medis di mana false negative memiliki konsekuensi serius.

3.2 Hasil Penyetelan *Hyperparameter* Jaringan Neural

Selama penyetelan *hyperparameter* Jaringan Neural, berbagai konfigurasi diuji untuk menentukan kombinasi parameter yang optimal untuk kinerja terbaik. Konfigurasinya mencakup variasi dalam jumlah node, tingkat dropout, tingkat pembelajaran, dan ukuran batch. Hasil percobaan ini dirangkum dalam Tabel 3.

Tabel 3. Penyetelan konfigurasi *Hyperparameter* pada data Lung Cancer

Nodes	Dropout	Learning Rate	Batch Size	Loss	Accuracy		
16	0	0.01	32	0.28	0.90		
			64	0.26	0.93		
		128	0.27	0.88			
		0.005	32	0.27	0.90		
			64	0.27	0.93		
			128	0.31	0.88		
	0.001		32	0.33	0.88		
		64	0.28	0.91			
		128	0.33	0.90			
		0.01	32	0.29	0.91		
	64		0.32	0.91			
	128		0.26	0.91			
32	0		0.005	32	0.27	0.93	
				64	0.29	0.90	
			128	0.27	0.91		
		0.001	32	0.34	0.87		
			64	0.26	0.91		
			128	0.27	0.90		
	0.01		32	0.38	0.85		
		64	0.27	0.90			
		128	0.27	0.90			
		64	0.005	0.005	32	0.39	0.88
					64	0.29	0.90
				128	0.25	0.91	
0.01	32			0.35	0.88		
	64			0.27	0.91		
	128			0.27	0.88		

Tabel tersebut adalah hasil eksperimen pada model *machine learning*, kemungkinan jaringan saraf tiruan, dengan variasi parameter seperti jumlah *nodes*, *dropout*, *learning rate*, dan *batch size*. Parameter *nodes* meliputi nilai 16, 32, dan 64. *Dropout* digunakan untuk mengurangi risiko *overfitting* dengan nilai 0, 0.01, 0.005, dan 0.001. *Learning rate* bervariasi antara 0.25 hingga 0.39, sedangkan *batch size* yang digunakan adalah 32, 64, dan 128. Evaluasi kinerja model meliputi perhitungan *loss* selama pelatihan dan akurasi terhadap data pengujian atau validasi.

Dari hasil eksperimen tersebut, temuan umum mencakup preferensi terhadap dropout dengan nilai 0.01 dan 0.005 untuk meningkatkan akurasi, serta penggunaan *batch size* 64 yang memberikan stabilitas dan akurasi yang baik. *Learning rate* rendah (0.25-0.26) juga terbukti efektif dalam mengurangi *loss* dan meningkatkan akurasi. Meskipun demikian, jumlah *nodes* yang lebih besar tidak selalu menghasilkan kinerja yang lebih baik, tergantung pada konfigurasi parameter lainnya. Analisis ini memberikan panduan untuk menentukan kombinasi parameter optimal yang sesuai dengan kebutuhan kinerja dalam aplikasi *machine learning*.

Dalam tabel eksperimen yang diberikan, akurasi tertinggi mencapai 0.93. Hasil ini tercatat pada dua kombinasi parameter yang berbeda: pertama, dengan 16 *nodes*, *dropout* 0.01, dan *batch size* 64, di mana model mencapai *loss* 0.26. Kedua, pada konfigurasi yang sama dengan *dropout* 0.005, yang juga memberikan akurasi 0.93 dengan *loss* 0.27. Menggunakan model dengan 16 *nodes*, *learning rate* 0.01, dan *batch size* 64 adalah yang terbaik berdasarkan hasil eksperimen. Model ini menunjukkan *loss* yang lebih kecil dibandingkan dengan konfigurasi lainnya. Selain itu, *learning rate* 0.01 terbukti lebih efisien dalam hal waktu komputasi dibandingkan dengan *learning rate* 0.005, karena model dengan *learning rate* 0.005 memerlukan waktu

konvergensi yang lebih lama. Oleh karena itu, kombinasi ini tidak hanya menghasilkan performa terbaik tetapi juga mempercepat proses pelatihan model.

Untuk memvalidasi kinerja model, hasil penelitian ini dibandingkan dengan metode yang dikembangkan oleh Reddy dan Khanaa [24]. Hasil menunjukkan bahwa model *k-Nearest Neighbors* (k-NN) dan *Neural Network* mencapai akurasi sebesar 92%, yang mendekati performa metode Proposed IDLA dengan akurasi sebesar 92,81% [24]. Perbedaan yang relatif kecil ini menunjukkan bahwa model yang diusulkan memiliki kinerja yang kompetitif dalam klasifikasi kanker paru-paru. Selain itu, model *Logistic Regression*, *Naïve Bayes*, dan *Support Vector Machine* (SVM) juga menunjukkan performa yang kompetitif dibandingkan dengan metode yang dilaporkan dalam penelitian sebelumnya [25], [26], [27].

4. KESIMPULAN

Hasil evaluasi model menunjukkan bahwa *K-Nearest Neighbors* (k-NN) dan *Neural Network* menonjol sebagai algoritma dengan performa terbaik dalam memprediksi kanker paru-paru, dengan tingkat akurasi mencapai 0.92. Kedua algoritma ini juga memiliki presisi tertinggi untuk kelas kanker paru-paru, mencapai 0.94, menandakan kemampuan yang sangat baik dalam mengenali kasus kanker paru-paru secara akurat. Di samping itu, *K-Nearest Neighbors* juga mencatat presisi tertinggi untuk kelas normal (0.89), sementara *Logistic Regression*, meskipun memiliki akurasi yang baik (0.90), menunjukkan presisi yang sedikit lebih rendah untuk kelas normal (0.80). Secara keseluruhan, *K-Nearest Neighbors* juga mencatat *recall* tertinggi untuk kelas kanker paru-paru (0.98), menunjukkan kemampuan untuk mendeteksi sebagian besar kasus kanker paru-paru yang terjadi. Sebaliknya, *Naïve Bayes* memiliki *recall* terendah untuk kelas yang sama (0.92). Evaluasi ini menggambarkan variasi dalam performa antar algoritma dalam prediksi kanker paru-paru, memberikan pemahaman yang penting bagi aplikasi klinis dan penelitian. Temuan ini dapat digunakan untuk memilih algoritma yang paling sesuai dengan kebutuhan spesifik dalam meningkatkan deteksi dini, manajemen penyakit, dan perawatan yang efektif bagi pasien dengan kanker paru-paru.

DAFTAR PUSTAKA

- [1] J. F. Idris, R. Ramadhani, M. M. Mutoffar, S. Tinggi, T. Bandung, and K. Bandung, "Klasifikasi Penyakit Kanker Paru Menggunakan Perbandingan Algoritma Machine Learning," *J. Media Akad.*, vol. 2, no. 2, 2024.
- [2] World Health Organization, "Cancer Fact Sheet," 2020.
- [3] L. Wang, "Deep Learning Techniques to Diagnose Lung Cancer," *Cancers (Basel)*, vol. 14, no. 22, p. 5569, 2022, doi: 10.3390/cancers14225569.
- [4] S. N. Fadilah, D. C. R. Novitasari, and L. Hakim, "Pengaruh Reduksi Fitur Pada Klasifikasi Kanker Paru Menggunakan CNN Dengan Arsitektur GoogLeNet," *Jurnal Fourier*, vol. 12, no. 1, pp. 20–32, 2023, doi: 10.14421/fourier.2023.121.20-32.
- [5] S. H. Hosseini, R. Monsefi, and S. Shadroo, "Deep Learning Applications for Lung Cancer Diagnosis: A Systematic Review," *Multimed. Tools Appl.*, vol. 83, pp. 1–45, 2024, doi: 10.1007/s11042-023-16046-w.
- [6] Y. Li, X. Wu, P. Yang, G. Jiang, and Y. Luo, "Machine Learning for Lung Cancer Diagnosis, Treatment, and Prognosis," *Genomics Proteomics Bioinformatics*, vol. 20, no. 5, pp. 850–866, 2022, doi: 10.1016/j.gpb.2022.11.003.
- [7] A. Esteva and others, "A Guide to Deep Learning in Healthcare," *Nat. Med.*, vol. 25, no. 1, pp. 24–29, 2019, doi: 10.1038/s41591-018-0316-z.
- [8] W. Shen *et al.*, "Multi-crop Convolutional Neural Networks for lung nodule malignancy suspiciousness classification," *Pattern Recognition*, vol. 61, pp. 663–673, 2017, doi: 10.1016/j.patcog.2016.05.029.
- [9] P. M. Shakeel, M. A. Burhanuddin, and M. I. Desa, "Automatic Lung Cancer Detection from CT Image Using Improved Deep Neural Network and Ensemble Classifier," *Neural Comput. Appl.*, vol. 33, pp. 281–299, 2021, doi: 10.1007/s00521-020-04842-6.
- [10] A. A. A. Setio *et al.*, "Validation, comparison, and combination of algorithms for automatic detection of pulmonary nodules in computed tomography images: The LUNA16 challenge," *Medical Image Analysis*, vol. 42, pp. 1–13, 2017, doi: 10.1016/j.media.2017.06.015.
- [11] A. Esteva *et al.*, "A guide to deep learning in healthcare," *Nature Medicine*, vol. 25, no. 1, pp. 24–29, 2019, doi: 10.1038/s41591-018-0316-z.
- [12] S. Florida, S. Hawkins, H. Wang, and A. Garcia, "Digital Commons @ University of Predicting Malignant Nodules from Screening CT Scans," 2016.

- [13] M. Kanan and others, "AI-Driven Models for Diagnosing and Predicting Outcomes in Lung Cancer: A Systematic Review and Meta-Analysis," *Cancers (Basel)*, vol. 16, no. 3, p. 674, 2024, doi: 10.3390/cancers16030674.
- [14] K. Omprakash and D. Samiappan, "A novel two-stage deep learning approach for lung cancer using enhanced ResNet50 segmentation and LungSwarmNet classification," *Sci. Rep.*, vol. 16, no. 1, pp. 1–17, 2026, doi: 10.1038/s41598-025-31000-6.
- [15] S. Huang, I. Arpacı, M. Al-Emran, and S. Kılçarslan, "A Comparative Analysis of Classical Machine Learning and Deep Learning Techniques for Predicting Lung Cancer Survivability," *Multimed. Tools Appl.*, vol. 82, pp. 1–25, 2023, doi: 10.1007/s11042-023-16349-y.
- [16] A. C. Pacurari and others, "Diagnostic Accuracy of Machine Learning AI Architectures in Detection and Classification of Lung Cancer: A Systematic Review," *Diagnostics*, vol. 13, no. 13, p. 2145, 2023, doi: 10.3390/diagnostics13132145.
- [17] T. Riahi and others, "Lung Cancer Management: Revolutionizing Patient Outcomes Through Machine Learning and Artificial Intelligence," *Cancer Rep.*, vol. 8, no. 1, p. e70240, 2025, doi: 10.1002/cnr2.70240.
- [18] M. Geppert and others, "Software Using Artificial Intelligence for Nodule and Cancer Detection in CT Lung Cancer Screening: Systematic Review of Test Accuracy Studies," *Thorax*, vol. 79, pp. 1040–1049, 2024, doi: 10.1136/thorax-2024-221662.
- [19] C. Pangestu, S. Shaufiah, and R. Wijaya, "X Spotify Cares Clustering Analysis using K-Means and K-Medoids," *Jurnal Media Informatika Budidarma*, vol. 8, no. 1, pp. 497–507, 2024.
- [20] D. Marutho, "Perbandingan Metode Naïve Bayes, KNN, Decision Tree Pada Laporan Water Level Jakarta," *Jurnal Ilmiah Infokam*, vol. 15, no. 2, pp. 90–97, 2019.
- [21] I. Firmansyah, J. T. Samudra, D. Pardede, and Z. Situmorang, "Komparasi Random Forest Dan Logistic Regression Dalam Klasifikasi Penderita Covid-19 Berdasarkan Gejalanya," *Journal of Science and Social Research*, vol. 5, no. 3, p. 595, 2022, doi: 10.54314/jssr.v5i3.994.
- [22] Saifuddin, L. Azhari, E. Widarti, and Wartono, "Evaluasi Kinerja Kernel Linear, RBF, dan Polynomial pada Model Support Vector Machine untuk Prediksi Risiko Hipertensi," *J. Ilm. FIFO*, vol. 17, no. 2, pp. 192–201, 2025, doi: 10.22441/fifo.2025.v17i2.008..
- [23] V. Y. P. Ardhana *et al.*, "Prediksi Flight Delay Berbasis Algoritma Neural Network," *Journal of Informatics, Electrical and Electronics Engineering*, vol. 2, no. 1, pp. 26–30, 2022, doi: 10.47065/jieee.v2i1.429.
- [24] N. S. Reddy and V. Khanaa, "Intelligent deep learning algorithm for lung cancer detection and classification," *Bulletin of Electrical Engineering and Informatics*, vol. 12, no. 3, pp. 1747–1754, 2023, doi: 10.11591/eei.v12i3.4579.
- [25] S. P. Maurya, P. S. Sisodia, R. Mishra, and D. P. Singh, "Performance of Machine Learning Algorithms for Lung Cancer Prediction: A Comparative Approach," *Sci. Rep.*, vol. 14, no. 1, p. 18562, 2024, doi: 10.1038/s41598-024-58345-8.
- [26] T. Meeradevi and others, "Lung Cancer Detection with Machine Learning Classifiers with Multi-attribute Decision-making System and Deep Learning Model," *Sci. Rep.*, vol. 15, no. 1, p. 88188, 2025, doi: 10.1038/s41598-025-88188-w.
- [27] D. Fabiyanto and Z. Pratama Putra, "Validasi Efektivitas Logistic Regression untuk Diagnosa Penyakit Jantung melalui Pendekatan Machine Learning," *J. Ilm. FIFO*, vol. 16, no. 2, p. 158, 2024, doi: 10.22441/fifo.2024.v16i2.006.