

BAB 1 PENDAHULUAN

1. 1. Latar Belakang

Pneumonia menurut French (2009), merupakan salah satu penyakit pernafasan yang menyerang bagian bawah paru. Penyakit ini sebagian besar disebabkan oleh bakteri, yang mengakibatkan terjadinya inflamasi pada kantong udara paru. *Pneumonia* Gram-negatif adalah infeksi paru yang disebabkan oleh bakteri Gram-negatif. Istilah *Gram* berasal dari nama penemunya, ilmuwan Denmark Hans Christian *Gram* (1853–1938) yang mengembangkan teknik ini pada tahun 1884 untuk membedakan bakteri *pneumokokus* dan *Klebsiella Pneumonia*.

Prasso (2017) pada penelitiannya mengatakan bahwa pada proses identifikasi melalui tes dahak dan hasil pewarnaan *Gram*, bakteri penyebab penyakit *Pneumonia* digolongkan menjadi dua, yaitu bakteri *Gram* Positif dan bakteri Gram-negatif. Bakteri Gram-positif merupakan bakteri yang mempertahankan zat warna kristal *violet* sewaktu proses pewarnaan *Gram* sehingga *isolate* akan berwarna biru atau ungu di bawah mikroskop. Sedangkan Bakteri Gram-negatif adalah bakteri yang tidak mempertahankan zat warna kristal *violet* sewaktu proses pewarnaan *Gram* sehingga akan berwarna merah bila diamati dengan mikroskop. Contoh bakteri Gram-negatif adalah *Acinetobacter Baumanii*, *Klebsiella Pneumoniae*, *Escherichia colli*, *Pseudomonas aeruginosa* dan *Haemophilus Influenta*.

Penelitian bakteri penyebab *pneumonia* yang diakibatkan bakteri Gram-negatif belum banyak dilakukan orang. Menurut Grosso (2015), Bakteri Gram-negatif merupakan bakteri penyebab *pneumonia* di iklim tropis seperti Indonesia. Bakteri Gram-negatif pada kebanyakan kasus cenderung bersifat *patogen*. Selain itu terdapat sifat nosokomial yaitu infeksi kuman yang terjadi ketika pasien dirawat di rumah sakit, dimana terdapat bakteri penyerta dari bakteri utama. Sifat nosokomial menyebabkan bakteri utama misalnya bakteri *Klebsiella* menjadi bersifat resisten.

Perangkat yang diperlukan dalam pengamatan bakteri di laboratorium adalah mikroskop. Menurut Chen (2011), mikroskop merupakan sebuah *instrument* yang berfungsi untuk melihat, atau mengenali benda-benda yang terlihat kecil menjadi lebih besar dari aslinya.

Bagian utama mikroskop yaitu sebuah lensa objektif dan sebuah lensa *okuler* yang merupakan lensa cembung. Sifat umum lensa cembung yaitu menghasilkan bayangan semu terbalik dan diperbesar. Mikroskop akan menghasilkan bayangan yang lebih besar dari benda itu sendiri. Tingkat pembesaran dipengaruhi oleh beberapa hal yaitu titik fokus lensa objektif dan lensa *okuler*, panjang jarak antara lensa objektif dan jarak pandang mata. Menurut Shamir (2010), selanjutnya diperlukan perangkat *software* untuk dapat mengenali gambar yang dibaca perangkat mikroskop yang dikenal sebagai *software* pengolahan citra. *Software* ini memiliki 4 tahapan yaitu perbaikan citra, segmentasi, ekstraksi fitur dan terakhir klasifikasi atau identifikasi. Untuk melakukan proses tersebut digunakan metode *machine learning* dan metode *deep learning*.

Algoritma *Machine learning* menurut Alam (2019), merupakan cabang dari kecerdasan buatan dan pengembangannya adalah sebuah sistem yang mampu belajar "sendiri" tanpa harus berulang kali di *program* oleh manusia. Algoritma *supervised Machine learning* diantaranya adalah *Decision Tree*, *Fuzzy*, *Random Forest*, dan *Extreme learning Machine*. Penggunaan *supervised learning* ini, pada kebanyakan kasus digunakan untuk menyelesaikan permasalahan data *non-image* namun tidak menutup kemungkinan dapat digunakan pada data *image* dengan cara memilih tahap ekstraksi fitur yang tepat. Sementara itu terdapat *metode state of the art penelitian image processing* yaitu *Convolutional Neural network*.

Penelitian pengolahan citra dilakukan oleh Hiremath (2013), menguji karakteristik *cell Image* bakteri dengan pewarnaan *Gram* menggunakan *color space* RGB ke YcbCr. penelitian ini melakukan *Image enhancement* menggunakan *Histogram entropy* untuk *equalization*, perbaikan global *Thresholding* dan perbaikan morfologi citra. Dari 100 *sample* yang diambil, didapatkan 58 pasien teridentifikasi *Gram* positif, 34 pasien *Gram*-negatif dan salah identifikasi 8 pasien sehingga nilai akurasi 92%.

Penelitian *supervised machine learning* lain dilakukan oleh Khatibi (2009), menggunakan pendekatan lima pengukuran kesamaan *fuzzy set* dan algoritma *fuzzy set* intuisi (IFS). Jumlah sampel bakteri yang digunakan 263 berasal dari laboratorium mikrobiologi Teheran. Hasilnya menggunakan *Fuzzy Set Hausdorf* dan *Mitchel*, memiliki ukuran *similarity* menunjukkan hasil terbaik dengan tingkat deteksi 95,27% dan 94,48%. Algoritma *supervised* berbasis *neural network* pada *machine learning* dengan waktu proses cepat salah satunya adalah *Extreme Learning Machine (ELM)*.

Penelitian *Extreme learning machine* pada umumnya digunakan untuk melakukan peramalan data berbasis *text*. Namun pada penelitian yang dilakukan oleh J. Cao (2016), *Extreme Learning Machine* diterapkan pada *partisi images bernoise* dengan SRC (*Sparse Representation Classification*) dan EA SRC (*Adaptive SRC*). Selain itu ELM diujicobakan pada *AR Face database* dengan 700 *data training*. Hasil akurasi klasifikasi adalah 94.74%. Selanjutnya terdapat penelitian yang dilakukan oleh H. Li (2019) menggunakan *Neural response-Extreme Learning Machine* (NR-ELM). Pada tahap *Preprocessing* digunakan *Dense SIFT (Scale Invariant Feature Transform)*, diikuti *Multilayer ELM*. Implementasi dilakukan pada *MNIST handwritten digits* dan *Caltech Face Database* dengan hasil rata rata klasifikasi 93,93%. Hasil ini menunjukkan bahwa *Extreme learning machine* dapat menjadi pertimbangan untuk melakukan klasifikasi *image* bakteri dengan waktu komputasi yang cepat

Penelitian terkait pengolahan citra pada bakteri juga dilakukan oleh Smith (2018) menggunakan *Convolution neural network* dengan pewarnaan *Gram*. Fokusnya pada latar belakang dan artefak pewarnaan, dimana terkadang artefak meniru bentuk dan warna sel bakteri. Pada penelitian ini diterangkan bahwa algoritma hanya mengandalkan intensitas warna *thresholding* dan deteksi bentuk akan memberikan akurasi yang kurang optimal. Penelitian ini menggunakan pelatihan *Convolutional Neural network* (CNN), dengan menggunakan total 25.488 gambar dari 180 *slide* secara otomatis dikumpulkan dari lokasi yang berbeda. Hasil Akurasi klasifikasi menggunakan CNN adalah 94,9%.

Disamping keunggulan CNN dalam hal akurasi, terdapat kelemahan CNN dalam hal waktu proses *training* karena menggunakan *layer* yang cukup banyak. Hal ini dikatakan T. Liu (2015) yang melakukan penelitian dengan mengukur waktu aktual komputasi *feed forward* dan *backpropagation*. Langkah yang dilakukan adalah menganalisis kecepatan maksimal menggunakan teori efisiensi *paralel*. Selain itu penelitian tentang waktu proses *training* juga dilakukan oleh Guedria (2019) dengan menggunakan Auto-CNNp yang berfungsi menangkap tugas rutin CNN berbasis *Message Passing Interface (MPI) communication protocol* yang mengidentifikasi paralelisme pada CNN, dan melatih model CNN secara efektif dalam waktu yang wajar.

Pada proses *training* CNN, untuk meningkatkan efisiensi *neural network* dapat dilakukan dengan melakukan *tuning* menggunakan *transfer learning*. Caranya adalah dengan melatih model yang telah dilatih oleh *googlenet* dengan model baru yang

ditraining dengan laju pembelajaran kecil sehingga tidak merusak model sebelumnya. Penelitian CNN dengan *bayesian* pada *image* bukan *image* bakteri telah dilakukan oleh Sameen (2020) mengatakan bahwa optimasi *bayesian* meningkatkan performa CNN sebesar kurang lebih 3% pada ujicoba *landslide susceptibility* dibanding konfigurasi aslinya. Selain itu terdapat juga penelitian yang dilakukan oleh Borgli (2019) untuk membedakan 8 kelas *gastrointestinal* menggunakan Kvasir *datasets* dan setelah dibandingkan dengan *best model* didapatkan nilai 10% lebih baik dengan optimasi.

Berdasarkan penjelasan tersebut, kontribusi penelitian ini adalah penggunaan pengolahan citra untuk membantu mengatasi masalah pengamatan visual yang masih diperlukan di laboratorium mikrobiologi. Perbedaan dengan penelitian sebelumnya adalah belum diperolehnya akurasi optimal dengan waktu minimal pada tahap identifikasi bakteri. Penelitian berbasis *machine learning* sebagai contoh *extreme machine learning* berdasarkan *review* memiliki akurasi berkisar pada 87% sampai dengan 97%. Pada penelitian dengan *Convolutional Neural network* hasil akurasi yang didapatkan lebih baik, namun pada proses *training* untuk menyusun *model* masih diperlukan waktu komputasi yang cukup lama. Hal ini terkait penggunaan *layer* yang cukup banyak untuk pembelajaran. Penelitian ini menggunakan data pasien primer dari Rumah Sakit Soetomo karena tidak tersedia data sekunder yang cukup di internet. Algoritma *Convolutional neural network* yang digunakan memiliki tahapan *feature maps*, *dropout* dan klasifikasi. Kebaruan teknis mengoptimalkan waktu komputasi proses *training* dengan tetap menjadi akurasi CNN tetap tinggi. Caranya dengan custom layer, augmentasi data, dan optimasi pencarian parameter yang tepat. Software yang digunakan adalah *python*, Mathlab 2019a, sementara hardwarenya menggunakan core i-7, RAM 8GB dan *Graphics Processing Unit* NVIDIA GTX1050 4GB.

penelitian ini juga melakukan ujicoba menggunakan *Single hidden layer Extreme Learning Machine* (ELM) dengan variasi *node* pada *hidden layer* yang dimplementasikan untuk klasifikasi *image* bakteri. Hal ini mengingat ELM memiliki waktu komputasi yang cepat pada proses klasifikasinya. Hasil akurasi dibandingkan dengan *Convolutional neural network*. Pada Rancangan Custom *Convolutional neural network* ditambahkan augmentasi data dan pencarian parameter optimal. Hal ini untuk memperbaiki kinerja CNN. Perbedaan keduanya seperti ditunjukkan pada tabel 1.1.

Tabel 1. 1. Tabel Perbandingan ELM dan CNN

No	Indikator	Neural Network	
		ELM	CNN
1	Jumlah Layer	Single Feed forward NN	Konsep Multi layer Perceptron dan Backprop
2	Fungsi / Kegunaan	Classifier	Feature maps dan Classifier
3	Jenis Data yang digunakan	Berbasis text	Image atau gambar
4	File atau direktori data yang digunakan	Hanya Data Train dan data test	Data Train, Data Test dan Data Validasi
4	Proses mendapatkan fitur	Dilakukan segmentasi, ekstraksi fitur bentuk, dan seleksi fitur	Tanpa Segmentasi dan ekstraksi fitur
5	Basis	Matrix More PenRose	Convolutional layer
6	Jumlah parameter	fitur yang dilatih saja $m \times n$	Matrix input x kernel filter
7	Pre-processing	diperlukan	Bisa Ya, bisa Tidak
8	Fungsi Aktivasi	Sigmoid, HardLim, RadBas	ReLU, Leaky Relu
9	Backpropagation	Tidak ada	Ada
10	Optimasi Training	tidak ada	Ada (adam, sgdm, rmsprop)
11	Optimasi pencarian parameter	tidak ada	Ada (Random search, Grid, bayesian)
12	Akurasi	95-97%	98-100%
13	Kecepatan	lebih cepat karena single layer	lebih lama karena proses pembelajaran
14	Augmentasi data	Tidak ada	Ada
15	Transfer Learning	Tidak ada	Ada
16	Waktu proses	detik	menit
17	Proses	Pemilihan fitur memerlukan proses yang cukup panjang agar mendapatkan akurasi yang baik	Proses feature maps lebih mudah

Tabel 1.1 menunjukkan bahwa performa CNN lebih menjanjikan dari segi akurasi, namun kekurangan waktu komputasi proses *training* menjadi bagian permasalahan yang harus diselesaikan. CNN tidak memerlukan tahapan segmentasi dan ekstraksi fitur yang memerlukan proses panjang. Tahapan ini digantikan proses *feature maps* dengan cara

melakukan konvolusi terhadap matriks *input* menggunakan *kernel filter*. Karena jumlah layer konvolusi banyak, maka proses *training* untuk menyusun model menjadi lebih lama, namun akurasi yang dihasilkan cukup tinggi. Hal ini menyebabkan proses akurasi prediksi CNN lebih menjanjikan dibandingkan ELM.

Selain pemilihan metode, perlu diperhatikan juga perbedaan proses identifikasi dan klasifikasi. Tabel 1.2 menjelaskan perbedaan proses identifikasi dilakukan pada tahapan segmentasi dan ekstraksi fitur. Tujuan identifikasi adalah untuk mendapatkan identitas warna, bentuk dan ciri dari bakteri. Indikator identifikasi yang digunakan sebelum CNN adalah *Area*, *Metric*, *Perimeter* dan *Eccentricity*. Sementara tujuan klasifikasi adalah menempatkan pada kelas target

Tabel 1.2. Tabel perbedaan Identifikasi dan Klasifikasi bakteri

No	Kategori	Identifikasi	Klasifikasi
1	Definisi	Analisis image dengan mengekstraksi ciri-ciri tertentu yang membantu dalam identifikasi objek. Contoh <i>Edge Detection</i>	pengelompokan <i>data test</i> menjadi kelompok kelas sesuai dengan model kelas yang telah disusun pada saat proses training
2	Proses	Identitas warna, bentuk, ciri-ciri	Seleksi output kelas
3	Metode	Segmentasi, Ekstraksi fitur, Seleksi fitur, <i>Feature maps</i> pada CNN	<i>K-NN</i> , <i>Random Forest</i> , <i>Naïve Bayes</i> , <i>Random Forest</i> , ELM, SVM, MLP
4	basis	warna, tepi, <i>morfologi</i> , <i>texture</i>	jarak, rule seleksi fitur, probabilitas, <i>ground truth</i> , parameter yang digunakan saat menyusun model

Tabel 1.2 menunjukkan bahwa pada metode sebelum CNN, data gambar diolah terlebih dahulu pada tahapan *pre-processing*. Contoh tahapan *pre-processing* adalah perbaikan *morfologi* dan penggunaan *filter* untuk mendeteksi tepi dari objek gambar dengan filter ditentukan di awal. Hal ini agak berbeda dengan CNN dimana karakteristik *filter* didapatkan setelah proses *training*.

Perbedaan CNN dengan metode pendahulunya adalah CNN menggunakan *layer* konvolusi untuk mendapatkan parameter fitur tanpa campur tangan manusia. CNN mengelompokkan *kernel filter* pada *minibatch size*, sehingga secara keseluruhan proses *feature maps* bergantung pada jumlah *filter* yang digunakan pada masing masing *layer*.

Algoritma sebelum CNN mengandalkan penentuan *filter awal* terbaik agar proses identifikasi objek pada gambar menjadi lebih mudah. Sementara pada CNN, *filter* awal adalah *kernel* konvolusi dengan penentuan *stride* dan *padding* tertentu. Selain itu terdapat proses *batch normalization*, ReLU *layer* dan *pooling layer* yang dilakukan secara bertahap sehingga *filter* pada tiap *layer* CNN memiliki karakteristik berbeda beda. Hal ini didapatkan setelah melalui proses *training* dan penyusunan model.

Pada implementasi penggunaan CNN, proses pada *kernel filter* yang digunakan adalah sama, yaitu proses konvolusi. Pada tahap *backpropagation* penggunaan *layer* aktivasi sedikit berbeda dengan algoritma *neural network* sebelumnya. Jika sebelumnya menggunakan contoh *sigmoid* untuk aktivasi *layer*, pada CNN menggunakan ReLU *layer*, hal ini untuk mengatasi masalah *deminising gradient* karena jumlah *layer* yang banyak. *Deminising gradient* merupakan penurunan nilai bobot saat melakukan *backpropagation*. Pada CNN dengan *feature maps*, ukuran *kernel*, dan dimensi *filter* yang digunakan cenderung mengecil sehingga fitur yang ditangkap semakin banyak. Akibatnya visualisasi *filter* pada *layer* setelah proses *training* juga berbeda untuk setiap tahapannya. Sehubungan dengan hasil karakteristik *filter* yang menunjukkan perbedaan tersebut, dapat dikatakan CNN melakukan pembelajaran secara mendalam. Hal ini dikarenakan parameter yang digunakan untuk mendapatkan fitur proses identifikasi tersebut semakin dalam dan semakin mengecil untuk tiap *layer feature mapsnya*, jumlah parameter yang digunakan banyak dan komputasinya meningkat, namun hasil akurasi semakin baik.

1. 2. Rumusan Masalah

Rumusan masalah pada penelitian ini adalah

1. Bagaimana mengidentifikasi bakteri Gram negatif menggunakan *Extreme learning Machine*
2. Bagaimana melakukan klasifikasi bakteri Gram-negatif dengan *Convolutional Neural network*
3. Bagaimana mendapatkan nilai *optimal parameter CNN* pada saat identifikasi bakteri Gram-negatif.

1. 3. Batasan Masalah

Penelitian ini dibatasi pada permasalahan identifikasi objek bakteri di bawah pengamatan mikroskop *fluorescence* menggunakan pengolahan citra. Data diambil di Laboratorium Mikrobiologi Rumah Sakit Dr. Soetomo periode Agustus 2018 sampai dengan Agustus 2019. Ukuran gambar yang dihasilkan *Optilab view* adalah 2560x2048 dengan 96 dpi dan 24-bit *depth*. Pembesaran lensa yang digunakan 1000x pembesaran meliputi 10x lensa okuler dan 100x lensa objektif.

Pengujian dengan *dataset* sekunder menggunakan *dataset* DIBAS (*Digital Image of Bacterial Species*) terdiri dari 660 *Images* dengan 33 *species* dari bakteri. Terdapat 4 jenis bakteri Gram-negatif yang diteliti yaitu *Acinetobacter baumannii*, *Pseudomonas Aaerugenusa*, *Klebsiella pneumonia*, dan *Nisseria Gonnorrhoe*. Masing masing bakteri berisi 20 *file* dengan dimensi 2048x1532, 72 dpi dengan 24-bit *depth*.

1. 4. Tujuan Penelitian

Tujuan penelitian ini, sehubungan dengan rumusan masalah adalah

1. Melakukan Identifikasi bakteri Gram-negatif dengan *Extreme learning Machine*
2. Melakukan Klasifikasi bakteri Gram-negatif dengan *Convolutional Neural network*
3. Mendapatkan nilai optimal parameter *Convolutional Neural network* pada saat identifikasi bakteri Gram-negatif

1. 5. Manfaat Penelitian

Setelah proses identifikasi berhasil dilakukan, maka manfaat pragmatis yang didapatkan adalah layanan proses pengamatan *visual* bakteri di laboratorium mikrobiologi dapat dilakukan dengan lebih cepat dan akurat. Sementara manfaat bagi ilmu pengetahuan adalah pengembangan penelitian di bidang matematika dan pengenalan pola menjadi lebih terarah tanpa memerlukan proses manual dan panjang untuk menyusun model dengan akurasi tinggi.

1. 6. Kebaruan Penelitian

Penelitian ini dibangun untuk memperbaiki kinerja pada identifikasi bakteri menggunakan *Extreme Learning Machine* dan *Convolutional neural network*. Kebaruan yang ditawarkan pada penelitian adalah pengamatan *visual* digantikan dengan

pengolahan citra sehingga proses identifikasi bakteri menjadi lebih mudah dilakukan oleh laboran di rumah sakit. Pada tahapan pemilihan topik, bakteri *Gram* negatif masih belum banyak dilakukan peneliti. Hal ini bisa dikarenakan sifat patogenitas bakteri *Gram* negatif hanya bisa diketahui melalui laboratorium. Selain itu bahwa tidak di semua tempat bakteri ini dapat bersifat patogen, namun juga memiliki sifat *nosocomial* yang dapat menyebabkan kerusakan dengan mengikuti kuman lain. Pada tahapan data penelitian, data primer diambil dari rumah sakit Dr. Soetomo dengan kriteria inklusi pasien yang terpapar *pneumonia*. Dataset sekunder bakteri *pneumonia* di internet, tidak menjelaskan *patogenitas* dan kerapatan bakteri. *Image* bakteri *Gram* negatif masuk ke dalam *dataset* bakteri secara umum. Pada *dataset* primer kepemilikannya jelas, karena terdapat *id barcode specimen*, nama pemilik, nama pasien, asal bangsal pemeriksaan, diagnosa awal penyakit yang diderita pasien dan jenis kumannya.

Pada tahap *pre-processing*, penelitian ini menggunakan *autocontrast* untuk memperjelas objek terhadap *background*. Pada *Convolutional neural network*, layer yang digunakan cukup banyak, sehingga komputasi proses *training* memakan waktu lama. Hal ini menjadi pertimbangan digunakannya *Custom layer* untuk menghemat waktu *training*. Skenario yang digunakan yaitu *sequence layer* dan *direct acyclic graph*. Pada proses *training* telah digunakan optimasi adam (*Adaptive Moment Estimation*), *sgdm* (*stochastic gradient descent with momentum*), dan *rmsprop* (*Root Mean Square Propagation*), namun untuk mendapatkan nilai *parameter optimal* perlu dilakukan *tuning*. Salah satunya menggunakan optimisasi *bayesian*. Tujuannya untuk mendapatkan nilai momentum dan *initial learning rate* yang tepat. Pada bagian akhir digunakan skenario gabungan CNN dengan *extreme learning machine* sebagai *classifier*.

Tabel 1.3 menunjukkan bahwa topik bakteri *Gram* negatif dengan pengolahan citra ini masih sangat minim dilakukan peneliti. Belum terdapat pembahasan patogenitas bakteri. Pada tahapan *pre-processing* CNN belum terdapat proses khusus. Arsitektur yang digunakan masih menggunakan *existing* arsitektur. Belum terdapat augmentasi data untuk menangani jumlah data terbatas dan belum terdapat penggunaan optimasi untuk mencari *parameter optimal*. Waktu *training* bergantung pada arsitektur CNN untuk mendapatkan model. Sementara pada tahap layanan pasien mikrobiologi, waktu pelayanan dan ketersediaan tenaga medis sangat menjadi perhatian, sehingga dibutuhkan sistem dengan penyusunan model yang efisien untuk mengidentifikasi bakteri.

Tabel 1. 3. Review Riset Klasifikasi bakteri dengan CNN

No	Author	Judul	Tahun	Metode	Kelas	Jumlah Data	Pato-gen	Pre-processing	Arsitektur	Augmentasi Data	Optimasi	Akurasi rata rata	Waktu (menit)
1	Kenneth P. Smith	<i>Automated Interpretation of Blood Culture Gram Stains by Use of a Deep Convolutional Neural Network</i>	2018	CNN	4	4000	NA	-	CNN Inception v3	NA	NA	94,9%	NA
2	Lei Huang, and TongWu	<i>Novel neural network application for bacterial colony classification</i>	2018	CNN	18	2491	NA	-	Conventional CNN, Alexnet and autoencoder	NA	NA	73%	NA
3	Dastidar and Ethirajan	<i>Whole slide imaging system using deeplearning-based automated focusing</i>	2020	CNN	4	1313	NA	-	MobileNetV2 network,	NA	NA	93,75%	NA
4	Edouard A. Hay,	<i>Performance of convolutional neural networks for identification of bacteria in 3D microscopy datasets</i>	2018	CNN	3	1302	NA	-	CNN with 2 Convolutional layer and Fully Connected	NA	NA	88%	2.5
5	M.Talo	<i>An Automated Deep Learning Approach for Bacterial Image Classification</i>	2019	CNN	33	660	NA	-	Resnet 50	NA	NA	99,12%	NA
6	Zielinski	<i>Deep learning approach to bacterial colony classification</i>	2017	CNN	33	660	NA	-	Fully Connected-CNN	NA	NA	97,24%	NA
7	Penelitian ini	<i>Identifikasi Gram-negatif bacteria menggunakan extreme learning machine dan convolutional neural network</i>	2020	CNN	4	1000	Ada	Auto contrast	Custom CNN	Ada	Bayesian	Skenario ujicoba	Skenario ujicoba

Note:

NA = Not Available