

**PRAPROPOSAL PENELITIAN DISERTASI**

**PENENTUAN KUALITAS TUNA LOIN  
MENGGUNAKAN METODE DEEP LEARNING  
NEURAL NETWORK**



**I GEDE SUJANA EKA PUTRA**

**FAKULTAS TEKNIK  
UNIVERSITAS UDAYANA  
DENPASAR  
2022**

**PRAPROPOSAL PENELITIAN DISERTASI**

**PENENTUAN KUALITAS TUNA LOIN  
MENGGUNAKAN METODE DEEP LEARNING  
NEURAL NETWORK**



**I GEDE SUJANA EKA PUTRA**

**PROGRAM STUDI DOKTOR ILMU TEKNIK  
FAKULTAS TEKNIK  
UNIVERSITAS UDAYANA  
DENPASAR  
2022**

**Lembar Persetujuan Pembimbing Akademik**

**PRAPROPOSAL PENELITIAN DISERTASI INI TELAH DISETUJUI**

**PADA TANGGAL 20 APRIL 2022**

Pembimbing Akademik



(Dr. Ir. Ida Bagus Alit Swamardika, M. Eng., IPM)  
NIP. 196612181994031001

Mengetahui:

Koordinator Program Studi Doktor Ilmu Teknik  
Fakultas Teknik Universitas Udayana

(Prof. D.M. Priyantha Wedagama, ST. MT. MSc. PhD.)  
NIP. 19700303 199702 1 005

**Praproposal Penelitian Disertasi Ini Telah Disetujui dan Dinilai  
oleh Panitia Penguji pada  
Program Doktor Ilmu Teknik  
Program Pascasarjana Universitas Udayana  
Pada tanggal 13 Mei 2022**

**Panitia Penguji Praproposal Penelitian Disertasi:**

Ketua : Dr. Ir. Ida Bagus Alit Swamardika, M.Erg., IPM

Anggota : 1. Prof. Dr. I Ketut Gede Darma Putra, S.Kom., M.T.

2. Prof. Dr. Ir. Made Sudarma, M.A.Sc., IPU., ASEAN Eng.

3. Dr. A. A. Kompiang Oka Sudana, S.Kom, M.T.

4. Prof. Ir. Ida Ayu Dwi Giriantari, M.Eng.Sc., Ph.D.

5. Dr. Eng. I Putu Agung Bayupati, S.T., M.T.

6. Dr. I Made Sukarsa, S.T., M.T.

## UCAPAN TERIMA KASIH

Puji syukur penulis panjatkan kehadirat Tuhan Yang Maha Esa atas berkat rahmat dan karunia-Nya, penulis dapat menyelesaikan penulisan laporan pra-proposal disertasi yang berjudul **“Penentuan Kualitas Tuna Loin Menggunakan Metode Deep Learning Neural Network”** dengan baik dan tepat waktu.

Penulis menyadari bahwa keberhasilan penyusunan laporan ini tidak lepas dari bimbingan, pengarahan dan bantuan dari berbagai pihak. Pada kesempatan ini, penulis menyampaikan rasa hormat dan terima kasih kepada:

1. Bapak Prof. D.M. Priyantha Wedagama, S.T., M.T., M.Sc, Ph.D., selaku Koordinator Program Studi Doktor Ilmu Teknik Universitas Udayana.
2. Bapak Dr. Ir. Ida Bagus Alit Swamardika, M.Erg., IPM selaku Pembimbing Akademik Program Studi Doktor Teknik Universitas Udayana.
3. Bapak Prof Dr. I K G Darma Putra, S. Kom., M.T., selaku calon Promotor Disertasi
4. Bapak Prof Dr. Ir. Made Sudarma, MASc., IPU., ASEAN Eng., selaku calon Co-Promotor 1 Disertasi
5. Bapak Dr. A.A.K. Oka Sudana, S. Kom., M.T. selaku calon Co-Promotor 2 Disertasi
6. Semua pihak yang telah membantu penulis dalam menyusun laporan.

Penyusunan laporan ini telah melalui serangkaian proses studi literatur dan konsultasi topik dengan calon tim Promotor. Meskipun demikian, bukan tidak mungkin masih terdapat beberapa kekurangan yang dimiliki. Oleh karena itu, penulis meminta maaf atas kekurangan penulisan proposal Pra-Kualifikasi ini.

Denpasar, 19 April 2022



(I Gede Sujana Eka Putra)  
Penulis

## ABSTRAK

Produk tuna merupakan salah satu produk ekspor unggulan Indonesia dengan total ekspor produk tuna sirip kuning pada periode Januari sampai Juli 2021 sebesar 1,2 juta ton ke Jepang, Amerika Serikat, Vietnam, Australia dan Singapura. Keakuratan penentuan kualitas *grade* ikan tuna mutlak diperlukan untuk menjamin keamanan pangan dan kualitas produk. Penentuan kualitas *grade* ikan masih ditentukan secara manual dengan mengidentifikasi bau, kondisi mata, insang, warna daging. Sampling daging ikan diambil dengan batang besi (*spike*) yang ditancapkan untuk mengambil irisan daging ikan, dan selanjutnya ikan dipotong menjadi loin dan digrading kembali. Proses penentuan grade secara manual beresiko tidak akurat sehingga diperlukan alat untuk menentukan kualitas daging ikan tuna.

Penelitian sebelumnya ada yang membahas pengenalan kesegaran dan kualitas ikan menggunakan profil bau dan warna dari sensor, pengenalan kesegaran dan kualitas ikan dari citra mata ikan. Menurut Robert DiGregorio, terdapat lima parameter penentu *grade* ikan tuna yaitu kesegaran, ukuran dan bentuk ikan, warna daging, tekstur, dan lapisan lemak. Grade dikelompokkan menjadi *grade #1* (mutu paling baik), *grade #2+*, *grade #2*, *grade #3* (mutu paling rendah).

Penelitian ini membangun alat akuisisi fitur daging tuna yaitu kesegaran dari bau dan lemak dengan sensor, citra warna dan tekstur dengan kamera. Semua fitur yang diperoleh selanjutnya dilatih menggunakan metode *deep learning neural network* dan *k-nearest neighbor* untuk menentukan kualitas *grade* loin dari fitur sampel uji, dan selanjutnya membandingkan unjuk kerja kedua metode. Kebaruan penelitian ini yaitu belum ada penelitian membangun alat untuk mengakuisisi profil bau, warna, tekstur dan kandungan lemak untuk mengenali kualitas tuna loin.

Kata kunci : kualitas *grade*, sensor gas, sensor *spectrometry*, *deep learning neural network*, *k-NN*

## DAFTAR ISI

### Halaman

SAMPUL DALAM	
LEMBAR PERSETUJUAN PEMBIMBING AKADEMIK .....	ii
PANITIA PENGUJI PRAPROPOSAL PENELITIAN DISERTASI .....	iii
UCAPAN TERIMA KASIH .....	iv
ABSTRAK.....	v
DAFTAR ISI .....	vi
DAFTAR GAMBAR .....	ix
DAFTAR TABEL .....	xi
BAB I PENDAHULUAN .....	1
1.1 Latar Belakang .....	1
1.2 Rumusan Masalah .....	8
1.3 Tujuan.....	9
1.4 Manfaat Penelitian.....	9
1.5 Batasan Penelitian .....	9
1.6 Kebaharuan Penelitian ( <i>Novelty</i> ).....	10
BAB II TINJAUAN PUSTAKA.....	11
2.1 <i>State of The Art</i> .....	11
2.2 Penentuan Kualitas dan Kesegaran Ikan Tuna .....	29
2.3 Jenis Sensor Gas.....	37
2.4 Spesifikasi Teknis Sensor.....	37
2.5 Perangkat Pengukuran Kadar Gas .....	44
2.6 Pemilihan Sensor Deteksi Kesegaran IkanError! Bookmark not defined.	
2.7 Standar Referensi Profil Bau Penentuan Kesegaran Error! Bookmark not defined.	
2.8 Kualitas <i>Grade Daging</i> Tuna Berdasarkan Kandungan Lemak dan Spektrum Warna.....	50
2.9 Akuisisi Profil Bau .....	52
2.10 Ruang Warna RGB Dan HSV .....	53
2.11 Akuisisi Fitur Tekstur Citra .....	54
2.11.1 Tekstur Histogram .....	55
2.11.2 Tekstur <i>Gray Level Co-occurrence Matrix</i> .....	56
2.12 Metode Spektrometri <i>Near Infrared</i> (NIR).....	58
2.13 Deep Learning Metode <i>Convolutional Neural Network</i> .....	62
2.13.1 Konvolusi CNN .....	62
2.13.2 Pooling CNN .....	63
2.13.3 ReLu Aktivasi.....	63
2.13.4 <i>Confusion Matrix</i> .....	64
2.14 Algoritma <i>k-Nearest Neighbor</i> .....	64
BAB III KERANGKA BERPIKIR, KONSEP PENELITIAN DAN HIPOTESIS ...	67
3.1 Kerangka Berpikir .....	67
3.2 Konsep Penelitian.....	69
3.3 Hipotesis Penelitian.....	72
BAB IV METODOLOGI PENELITIAN .....	73
4.1 Peta Penelitian .....	73

4.2 Rancangan Penelitian .....	74
4.2.1 Tahapan Penentuan Kualitas Grade Tuna Loin Secara Umum.....	74
4.2.2 Tahap Akuisisi Data (Data Pelatihan) .....	74
4.2.3 Skematik Diagram Sensor.....	74
4.2.4 Kalibrasi Sensor Gas .....	74
4.2.5 Tahap Pelatihan Fitur Loin.....	79
4.2.6 Tahap Pengujian Sampel Loin Uji .....	79
4.2.7 Deteksi Tingkat Kesegaran Loin Dari Bau Menggunakan Sensor Gas.....	80
4.2.8 Deteksi Kandungan Lemak Loin Dengan Sensor Spektrometer.....	81
4.2.9 Akuisisi Citra Loin .....	81
4.2.10 Konversi Citra Warna RGB ke HSV.....	82
4.2.11 Konversi Citra Loin Dari RGB ke <i>Grayscale</i> .....	83
4.2.12 Ekstraksi Fitur Tekstur Dengan <i>Gray Level Co-occurrence Matrix</i> (GLCM) .....	83
4.2.13 Pelatihan Fitur Menggunakan Algoritma <i>Deep Learning</i> <i>Convolutional Neural Network</i> .....	86
4.2.14 Pelatihan Fitur Menggunakan Algoritma <i>k-Nearest Neighbor</i> .....	86
4.2.15 Pengujian Model Klasifikasi .....	90
4.2.16 Akurasi Klasifikasi Model CNN .....	91
4.2.17 Visualisasi Data.....	92
4.3 Lokasi dan Waktu Penelitian.....	92
4.4 Ruang Lingkup Penelitian .....	93
4.5 Penentuan Sumber Data Penelitian .....	94
4.5.1 Jenis Sumber Data.....	94
4.5.2 Populasi Dan Sampel Data Penelitian .....	94
4.5.3 Teknik Pengumpulan Data .....	95
4.6 Variabel Penelitian .....	97
4.7 Instrumen Penelitian.....	97
4.7.1 Alat Penelitian .....	97
4.7.2 Perangkat Lunak.....	98
4.8 Prosedur Penelitian.....	99
4.9 Cara Analisis Data.....	99
DAFTAR PUSTAKA .....	103

## DAFTAR GAMBAR

	<b>Halaman</b>
2.1 <i>Fishbone State of the Art</i> Penentuan Kualitas Ikan.....	19
2.2 Sensor MQ-4.....	38
2.3 Karakteristik Sensitivitas Sensor MQ-4.....	39
2.4 Sensor MQ-136 .....	40
2.5 Karakteristik Sensitivitas Sensor MQ-136.....	41
2.6 Sensor MQ-137 .....	42
2.7 Karakteristik Sensitivitas Sensor MQ-137.....	43
2.8 MESTEK CDGA02A.....	44
2.9 Wintact WT8822.....	45
2.10 <i>Hydron AM-40 Ammonia Test Paper</i> .....	46
2.11 Ilustrasi Pengukuran Profil Bau Tuna Loin .....	53
2.12 Kubus Warna RGB.....	53
2.13 Ruang Warna HSV.....	54
2.14 Tekstur Halus .....	55
2.15 Tekstur Kasar .....	55
2.16 Contoh Hasil Tekstur <i>Gray Level CoOccurrence Matrix</i> .....	58
2.17 Diagram Penampakan Specular (a) <i>diffuse</i> (b) <i>reflectances</i> (c) <i>absorption</i> radiasi <i>near infrared</i> dari sebuah sampel.....	59
2.18 Sensor <i>Sparkfun Spectroscopy AS 7263</i> .....	60
2.19 Jaringan Konvolusional <i>Deep Learning</i> .....	62
2.20 Contoh Konvolusi.....	63
2.21 Fungsi Aktivasi <i>Rectified Linear Unit</i> .....	63
3.1 Diagram Konsep Penelitian .....	71
4.1 Peta Penelitian .....	74
4.2 Rancangan Alat Penentuan Kualitas Tuna Loin .....	75
4.3 Skema Diagram Akuisisi Data.....	76
4.4 Skema Diagram Proses Pelatihan Fitur Input .....	77
4.5 Skema Diagram Akuisisi Data Sampel Uji .....	79
4.6 Skema Diagram Penentuan Data Sampel Uji .....	79
4.7 Model Proses Akuisisi Fitur Bau. ....	80
4.8 Model Proses Akuisisi Fitur Lemak/Minyak.....	81
4.9 Contoh Matriks Citra Input.....	81
4.10 Contoh Kombinasi Nilai Piksel Matrix 3 x 3 .....	83
4.11 Contoh Matrix GLCM Sudut 0 <sup>0</sup> .....	84
4.12 Contoh Penjumlahan Matrix GLCM dengan GLCM <i>Transpose</i> Sudut 0 <sup>0</sup> .....	84
4.13 Contoh Hasil Penjumlahan Matrix GLCM dan <i>Transpose</i> Sudut 0 <sup>0</sup> . .....	84
4.14 Contoh Hasil Normalisasi Matrix GLCM .....	84
4.15 Contoh Proses Konvolusi .....	85

4.16 Fungsi Aktivasi ReLu.....	87
4.17 Operasi <i>Max Pooling</i> .....	88
4.18 Siklus Hidup Pengembangan Sistem.....	88

## DAFTAR TABEL

	<b>Halaman</b>
2.1 Rangkuman Penelitian Sebelumnya .....	19
2.2. Kriteria <i>Grading</i> Produk Tuna Loin .....	31
2.3. Kriteria <i>Grading</i> Produk Tuna Loin Menurut <i>Luxe Gourmet</i> .....	32
2.4. Kriteria <i>Grading</i> Produk Tuna Loin Menurut <i>Sydney Fish Market</i> .....	33
2.5 Kriteria <i>Grading</i> Tuna Menurut Robert DiGregorio.....	34
2.6 Kriteria Ikan Segar .....	36
2.7 Jenis Sensor Gas dan Kegunaannya .....	37
2.8 Spesifikasi Teknis Sensor MQ-4.....	39
2.9. Spesifikasi Teknis Sensor MQ-136.....	41
2.10. Spesifikasi Teknis Sensor MQ-137.....	43
2.11. Spesifikasi Teknis Mestek CDGA02A .....	44
2.12. Spesifikasi Teknis Wintact WT8822 .....	45
2.13. Spesifikasi Teknis Hydrion AM-40, <i>Ammonia Test Paper</i> .....	46
2.14. Karakteristik Grading Daging Tuna.....	47
2.15. Perbandingan Sistem Grading Tuna .....	48
2.16. Persyaratan Mutu dan Keamanan Ikan Segar Berdasarkan Bau .....	49
2.17. Persyaratan Mutu dan Keamanan Ikan Segar Berdasarkan Tekstur .....	49
2.18. Kualitas <i>Grade</i> Daging Tuna Berdasarkan Kandungan Lemak.....	50
2.19. Kualitas <i>Grade</i> Daging Tuna Berdasarkan Warna Potongan Ekor dan Sampel Inti .....	51
2.20. Kualitas <i>Grade</i> Daging Tuna Berdasarkan Spektrum Warna .....	51
2.21. Spesifikasi Teknis Sensor AS-7263 .....	60
2.22. <i>Confusion Matrix</i> .....	64
4.1. Waktu Respons dan Waktu Pemulihan Sensor .....	76
4.2. Kelas Prediksi <i>Confusion Matrix</i> .....	90

## **BAB I**

### **PENDAHULUAN**

#### **1.1 Latar Belakang**

Produk tuna merupakan salah satu produk ekspor unggulan tujuan ke Amerika Serikat, Eropa, Jepang, dan Asia Tenggara. Ikan Tuna-Cakalang-Tongkol (TCT) merupakan salah satu komoditas ekspor Indonesia berperanan penting dalam perikanan tuna global. Identifikasi kualitas ikan diperlukan untuk menjamin kualitas dan keamanan produk bagi konsumen, semakin baik kualitas produk maka harga jual produk semakin baik dan keamanan pangan bagi konsumen pasar internasional lebih terjamin. Kualitas produk perikanan sampai ke konsumen didukung oleh ketersediaan data penelusuran rantai suplai asal usul ikan, proses pengolahan hingga pengiriman produk ke pelanggan.

Keberadaan ikan TCT di wilayah Indonesia tersebar mulai dari perairan selatan Jawa, laut Banda, laut Maluku, laut Flores, laut Sulawesi, laut Halmahera, perairan barat Sumatera, perairan utara Sulawesi dan perairan utara Aceh, Teluk Tomini, Teluk Cenderawasih, dan laut Arafura(Supriatna et al., 2014). Komoditas ikan tuna merupakan komoditas ekspor yang penting dan Indonesia perlu menjaga kualitas produk agar memiliki daya saing pasar global. Hasil tangkapan TCT Indonesia tahun 2017 mencapai 1,3 juta ton (20,06% produksi dunia)(Toni Rudi Hartanto et.al, 2021) dan nilai ekspor tuna sirip kuning pada periode Januari sampai Juli 2021 sebesar 1,2 juta ton ke beberapa pasar utama yaitu Jepang, Amerika Serikat, Vietnam, Australia dan Singapura(Nasional.kontan.co.id, 2021).

Beberapa kasus ditolaknya produk perikanan Indonesia oleh Amerika Serikat merupakan salah satu bukti masih kurangnya pengelolaan keamanan pangan di Indonesia(Humas BRSDM, 2021). Berdasarkan data BPOM di Indonesia, bulan Januari hingga Maret 2017 tercatat 23 insiden dan 893 orang yang mengalami keracunan makanan, dan tahun 2017 kasus keracunan makanan di Yogyakarta dengan korban mencapai 79 orang yang disebabkan bakteri E.Coli dan Salmonela(Rokhmayanti & Heryantoro, 2017). Berdasarkan kejadian yang disebutkan diatas, pengelolaan kualitas ikan perlu ditingkatkan kembali. Sejak 2019 Amerika

Serikat menerapkan program *seafood import monitoring program*(Noaa, 2018), regulasi untuk mengimpor produk perikanan yang memiliki data ketertelusuran yang tercatat untuk mencegah penangkapan ikan ilegal, tidak tercatat dan tidak diatur Undang-Undang (IUU) untuk masuk ke perdagangan Amerika Serikat. Aturan ini mendukung perlindungan pada ekonomi nasional, kemanan pangan global dan menjamin keberlanjutan sumber daya perikanan.

Kondisi yang diamati di lapangan, proses penentuan *grade* ikan tuna di perusahaan pengolahan ikan tuna, setelah diterima dari nelayan dan pemasok dilakukan secara manual oleh operator *checker* dengan cara *sensory* yaitu mengambil sampel irisan daging ikan bagian ekor, dan mengamati kondisi fisik ikan, mencium bau ikan dan mengamati warna dari sampel daging ikan. Pengambilan sampel irisan daging ikan menggunakan batang besi yang disebut *spike* (Sidik et al., 2013). Penentuan kualitas *grade* tuna loin secara manual oleh operator *checker* beresiko menimbulkan kesalahan atau ketidakakuratan akibat adanya *human error* dari faktor kelelahan.

Perkembangan teknologi saat ini sudah ada perangkat elektronik untuk mendeteksi kesegaran ikan berdasarkan bau dan rasa menggunakan alat *electronic nose*. *Electronic nose* ini meniru kemampuan indera manusia memanfaatkan beberapa sensor kimia dan modul sistem pengenalan pola untuk menghasilkan pola sinyal yang digunakan untuk mengkarakterisasi profil bau. *Electronic nose* mencakup tiga bagian utama yaitu sistem pengiriman sampel, sistem deteksi, sistem komputasi. Sistem pengiriman sampel berupa bagian yang menganalisis bagian kecil sampel, memasukkan sampel (*headspace*) ke dalam sistem deteksi *electronic nose*. Sedangkan sistem deteksi terdiri dari seperangkat sensor, saat bersentuhan dengan senyawa volatil, sensor bereaksi dan mengalami perubahan sifat listrik. Pada *electronic nose*, sensor sensitif terhadap molekul yang mudah menguap karena menggunakan protein reseptor yang merespons molekul bau tertentu. *Electronic nose* menggunakan susunan sensor kimia yang bereaksi terhadap senyawa volatil saat kontak. Jika terdapat senyawa volatil pada permukaan sensor menyebabkan perubahan fisik sensor yang mengubah sinyal menjadi nilai digital. Pola nilai digital yang diidentifikasi dari sensor bau, menghasilkan deretan pola yang dapat dilatih dengan metode komputasi tertentu untuk mendeteksi bau tertentu, pada bagian sistem komputasi *electronic nose*.

Posisi *novelty* pada penelitian ini yaitu membangun alat yang mengkombinasikan sensor bau dan sensor lemak. Sensor bau digunakan untuk mendeteksi tingkat kesegaran daging tuna loin. Menurut beberapa referensi, tingkat kesegaran daging ditentukan dari tingkat bau amoniak, bau asam sulfat dan bau methana dari daging(Pusdik.kkp.go.id, 2019). Alat yang dibangun, terdiri dari rangkaian sensor gas untuk mendeteksi tingkat kesegaran daging dari deteksi level bau amoniak, asam sulfat dan gas methana. Pada alat yang dibangun juga menggunakan sensor lemak (AS-7263), sensor *spectrometry* untuk mendeteksi fitur lemak dari daging ikan tuna dengan menggunakan panjang gelombang *near infrared*. Nilai sensor berupa nilai yang diserap oleh sensor dari pantulan cahaya *near infrared* 6 kanal yang dikenakan pada daging tuna(Khodabakhshian et al., 2017).

Beberapa penelitian sebelumnya membahas mengenai kesegaran dan kualitas ikan. Penelitian dari F. Han et al. (2014) meneliti deteksi kesegaran ikan menggunakan elektronik *tongue* dengan algoritma *nonlinear multivariate*, mengukur sampel ikan dari *Total volatile basic nitrogen* (TVB-N) dan *total viable count* (TVC), dan membandingkan dua metode yaitu *Fisher liner discriminant analysis* (*Fisher LDA*) dan metode *Support Vector Machine* (SVM) dalam mengklasifikasikan sampel pada hari yang berbeda. Hasil yang diperoleh adalah model SVM lebih baik dari model *Fisher LDA* 97.22% dalam prediksi kesegaran ikan(F. Han et al., 2014). Penelitian dari Najib et al. (2016) meneliti kualitas ikan dari profil bau dengan algoritma *Case Base Reasoning* (*CBR*), dengan menggunakan *electronic nose* (*E-nose*) untuk mengetahui kesegaran ikan yang diawetkan dengan *formalin*. Data profil bau dari sampel ikan dikumpulkan dan diolah menggunakan MATLAB, dan dinormalisasi. Fitur di input dan diklasifikasi menggunakan metode *CBR* yang dapat mengenali kesegaran ikan dengan tingkat akurasi 100%(Najib et al., 2016). Selanjutnya penelitian Dharmendra (2020) meneliti mengenai sistem cerdas untuk penilaian kualitas kesegaran ikan ikan nila (*tilapia*), ikan mas (*carpio*), dan ikan *tengra* menggunakan jaringan syaraf tiruan, dengan mengklasifikasikan langsung (*real time*) kesegaran ikan menggunakan *Artificial Neural Network* (ANN). Penelitian menggunakan sensor gas *MQ series* (MQ-2, MQ-4, MQ-7, MQ-8, MQ-5 dan MQ-135), yang dikombinasikan dengan mikrokontroler *Arduino Uno* untuk mengukur level kesegaran ikan. Algoritma ANN dilatih dengan banyak sampel ikan, dan proses

pengujian algoritma menggunakan data ikan segar (hari 1), semi segar (hari kedua), dan ikan tidak segar (hari ketiga) dengan menggunakan 9 sampel dari 3 jenis *spesies* berbeda. Hasil klasifikasi diperoleh *mean square error*  $1.4155 \times 10^{-17}$  pada 9022 epoh untuk ikan nila (*tilapia*), *mean square error* of  $5.9805 \times 10^{-13}$  pada 9448 epoh untuk ikan mas (*carpio*) dan MSE  $5.925 \times 10^{-18}$  pada 10,000 epoh untuk ikan *tengra*. Sistem dengan algoritma *artificial neural network* mampu mengidentifikasi kesegaran ikan dari jumlah hari setelah penangkapan ikan dengan akurasi sampai 99% (Kumar & Kumar, 2020).

Beberapa penelitian menggunakan metode *deep learning neural network* telah dilakukan sebelumnya. Penelitian dari Suresh et al. (2021) meneliti identifikasi kesegaran ikan menggunakan *deep learning*. Algoritma klasifikasi menggunakan jaringan *VGG-16* melalui *transfer learning* untuk memprediksi persentase kesegaran, sisa umur simpan ikan melalui fitur input berupa citra mata, citra insang, dan perubahan warna kulit. Data dikumpulkan dari sejumlah 6000 sampel dari sejumlah pasar ikan dan beberapa toko di wilayah *Kerala* menggunakan kamera selama periode waktu 3 hingga 4 bulan. Setelah data terkumpul, selanjutnya dilakukan pra-pemrosesan untuk memilih gambar dan model yang paling sesuai. Kesegaran ikan dapat diidentifikasi dengan menganalisis kondisi mata dan insang. Hasil yang diperoleh menunjukkan bahwa unjuk kerja algoritma *VGG-16* dapat mengklasifikasikan kesegaran ikan dengan akurasi hasil yang sama dengan dengan cara manual (Suresh et al., 2021). Penelitian dari Nugroho et al. (2020) yang mengimplementasikan *deep learning* algoritma *Convolutional Neural Network* (CNN) untuk mengenali ekspresi wajah manusia. CNN memiliki beberapa lapisan (*layer*) yang mengekstraksi informasi dari gambar dan menentukan klasifikasi gambar berupa skor klasifikasi. Tahapan yang dilakukan terdiri dari tahap *pre-processing* citra dan tahap klasifikasi. Dataset terdiri dari ekspresi senang, sedih, takut, perasaan biasa saja / netral, marah, dan kaget. Proses training dilakukan menggunakan *batch size*, dan *epoch* yang berbeda untuk mendapatkan model terbaik. Dengan *epoch* 100, dan *batch size* 128 didapatkan hasil akurasi *training* sebesar 90% dan tingkat validasi sebesar 65%. Hasil percobaan dari *dataset* 35 ekspresi wajah diperoleh 28 ekspresi berhasil ditebak dengan benar dengan akurasi sebesar 80% (Nugroho et al., 2020). Penelitian dari Lu et al. (2020) melakukan identifikasi spesies ikan tuna dan *billfish* menggunakan

*Deep Learning Neural Network.* Adanya kebutuhan informasi dari kapal penangkap ikan untuk melaporkan *spesies* tangkapan ikan. Pelaporan dan pencatatan data masih dilakukan secara manual sehingga kemungkinan beresiko ada kesalahan (*missreporting*). Penelitian ini mengidentifikasi *spesies* tuna dan *billfish* menggunakan *deep learning convolutional neural network* berdasarkan data input berupa citra ikan. *Spesies* yang diidentifikasi meliputi *tuna albacore* (*thunnus alalunga*), tuna mata besar (*thunnus obesus*), tuna sirip kuning (*thunnus albacares*), *blue marlin* (*makaira nigricans*), ikan layar Indo-Pasifik (*istiophorus platypterus*), dan ikan todak (*xiphias gladius*). Akuisisi citra hasil tangkapan ikan dilakukan di geladak kapal penangkap ikan. Identifikasi spesies dengan metode ini mencapai akurasi sampai 96,24% (Lu et al., 2020). Penelitian dari Prasmatio et al. (2020) melakukan deteksi dan pengenalan identitas jenis ikan menggunakan algoritma *convolutional neural network*. Metode diimplementasikan dengan bantuan *library OpenCV* untuk deteksi objek dan perangkat kamera. Data yang digunakan berupa gambar dari hasil video secara langsung menggunakan *webcam*. Pada penelitian ini dilakukan 6 kali percobaan *training* untuk ditemukan nilai paling baik, dan mendapatkan nilai *test score* 2.475, *test accuracy* 0.4237 dan *loss* sebesar 2.2002. Penelitian ini menghasilkan tingkat akurasi sebesar 85,18% dengan pengujian 27 kali yang dimana 4 kali tidak dapat mengidentifikasi foto dan 23 kali berhasil dalam mengidentifikasi foto ikan.

Terdapat beberapa penelitian mengenai identifikasi kualitas ikan. Penelitian dari Pakaya dan Suleman (2018) melakukan pengelompokan kualitas daging ikan tuna dengan *K-Means* berbasis histogram derajat keabuan. Ikan tuna yang memiliki kualitas dan mutu yang bagus dikirim ke Makassar, Surabaya, Jakarta, dan Bali, dan selanjutnya di ekspor. Penentuan kualitas daging ikan tuna yang dilakukan oleh petugas *grading (checker)* dengan memotong ikan tuna menjadi empat bagian daging yaitu daging sisi kiri dan kanan, dan mengamati daging tuna (*loin*) untuk mengidentifikasi kualitasnya. Namun penentuan kualitas dengan cara ini sering menimbulkan kesalahan dalam pengelompokan mutu dan kualitas daging tuna. Penelitian ini melakukan pengelompokan kualitas daging ikan tuna menggunakan metode *clustering K-Means* berbasis histogram derajat keabuan. Penggunaan metode ini menghasilkan *clustering* terbaik yaitu 3 kelompok kualitas daging ikan tuna yaitu *cluster A*, *cluster B*, dan *cluster C*(Pakaya & Suleman, 2018).

Penelitian dari Naimullah et al. (2020) melakukan klasifikasi *kualitas* grade daging tuna menggunakan *Color Histogram* dan *Grey Level Co-Occurrence Matrix (GLCM)*. Kualitas tuna dapat ditentukan secara organoleptik (*visual*) yang memeriksa warna, tekstur, bau, dan penampakan. Tahapan pertama yaitu akuisisi citra dan prapemrosesan (*cropping* citra). Selanjutnya dilakukan ekstraksi fitur menggunakan GLCM dan *Color Histogram* dan kemudian menggabungkan kedua fitur tersebut. Selanjutnya data dinormalisasi dan ditentukan parameternya. Data dilatih dan diuji berdasarkan model evaluasi dengan 4 skenario. Skenario 1, klasifikasi kualitas *grade* daging tuna menggunakan *Histogram*, *GLCM* dan *RGB*. Sedangkan skenario 2 menggunakan *Histogram*, *GLCM* dan *HSV*. Skenario 3 menggunakan *RGB* dan *HSV Histogram* dan *GLCM* dengan parameter *SVM* default, dan skenario 4 menggunakan *histogram* warna dan GLCM dengan parameter *SVM* yang diatur (*penalty* = 11, *dual* = *false*). Hasil klasifikasi menunjukkan skenario 1 dengan akurasi 61.66%, sedangkan skenario 2 dengan akurasi 79.1%. Skenario ke 3 menghasilkan akurasi 76.6% dan skenario ke 4 menghasilkan akurasi 81.6%. Hasil klasifikasi terbaik diperoleh pada penggunaan *Color Histogram* digabungkan dengan metode *Gray Level Co-Occurrence Matrix* dengan akurasi 81,6% dengan pengaturan parameter klasifikasi pada algoritma *Support Vector Machine* (Naimullah et al., 2020).

Penelitian ini menggunakan beberapa referensi sebagai dasar penentuan *grade tuna loin*. Menurut Robert DiGregorio dalam bukunya *Tuna Grading and Evaluation* (DiGregorio, 2012) menyatakan terdapat 5 ciri dalam *grading* ikan tuna yaitu *freshness* (kesegaran), ukuran dan bentuk ikan, warna daging, tekstur, lapisan lemak pada daging ikan. Teknik *sensory* digunakan untuk menilai mutu ikan menggunakan indera manusia dalam pengelolaan kualitas produk pangan, pengendalian kualitas dan pengembangan produk pangan(Nasional, 2006). Mutu ikan dan hasil produk perikanan dapat dikenali berdasarkan *sensory assessment*, terdiri dari penampilan ikan, bau (bau segar/bau tengik ikan) dan rasa (kesegaran, rasa, sifat manis di mulut, ketengikan, bau asap, asam, pahit), dan tekstur (kelembutan, kehalusan, elastisitas, kerapuhan, kekasaran)(FAO, 1989). *Grade* produk tuna loin menurut (DiGregorio, 2012)(Gourmets, 2021) terbagi menjadi 4 grade yaitu *grade #1*, *grade #2+*, *grade #2*, *grade #3*, dimana *grade #1* dan *grade #2+* merupakan *grade* terbaik dari produk tuna loin, produk dengan *grade* ini biasanya digunakan untuk produk mentah seperti *sushi*,

*sashimi, saku, steak* yang di ekspor ke pasar internasional Jepang(Sidik et al., 2013). Sedangkan produk dengan *grade #2*, akan mengalami proses *treatment smoke gas* karbonmonoksida terlebih dahulu untuk membuat warna produk lebih baik dan dibekukan terlebih dahulu dan di ekspor ke pasar internasional. Sedangkan produk dengan *grade #3* memiliki kualitas paling rendah dari produk ikan tuna yang diolah menjadi produk olahan dan dipasarkan di pasar domestik. Gourmets (2021) menyatakan penentuan *grading* ikan dilakukan berdasarkan warna daging, tekstur dan minyak pada daging. Selain itu kualitas *grade* ikan tuna dapat ditentukan dari bau, warna kulit, insang, isi perut dan elastisitas daging tuna loin(Sydney Fish Market Pty Ltd, 2015). Penelitian dari Bartam et al. (1996) menentukan grading ikan berdasarkan kesegaran, ukuran, warna daging, tekstur dan kandungan lemak (Bartam et al., 1996).

Berdasarkan hasil telaah literatur, penelitian tentang kualitas ikan telah banyak dilakukan pada penelitian sebelumnya, mulai dari pengukuran kesegaran ikan, dan kualitas ikan. Penelitian sebelumnya lebih banyak mengukur kesegaran ikan dan kualitas menggunakan profil bau dari sensor elektronik, profil warna RGB dari sensor warna, spektroskopi, biosensor kimia, sensorik mikrobiologi, kesegaran dan kualitas ikan dengan citra mata ikan dengan *artificial neural network* dan *convolutional neural network*, *hyperspectral imaging*, dan algoritma *wavelet* diskrit. Terdapat juga beberapa penelitian mengukur kadar lemak daging, susu atau kualitas jeruk menggunakan metode *near infrared hyperspectral imaging* yang dapat digunakan sebagai referensi dalam penelitian berikutnya. Dari sisi kebaruan penelitian, berdasarkan hasil telaah literatur sejauh yang dikenali penulis, sudah ada penelitian mengenai penentuan kualitas *grade tuna loin* sebelumnya berdasarkan warna dan tekstur daging saja, namun belum ada alat untuk menentukan kualitas grading tuna loin berdasarkan karakteristik bau, warna daging, tekstur dan lemak tuna loin (DiGregorio, 2012).

Menurut standar nasional Indonesia (SNI, 2013) (SANTHI, 2017), salah satu parameter untuk menentukan tingkat kesegaran ikan (ikan segar atau tidak segar) adalah parameter bau berdasarkan *sensory assessment*. Penelitian ini mengukur tingkat kesegaran loin tuna berdasarkan level bau, dengan instrumen menggunakan sensor gas MQ-4 (deteksi gas methana), sensor gas MQ-136 (deteksi gas asam sulfat) dan sensor MQ-137 (deteksi gas amoniak) dengan mikrokontroler *Arduino Uno*.Penentuan menggunakan sensor gas MQ berdasarkan pertimbangan harga sensor yang cukup

murah namun cukup handal dalam mendeteksi gas. Kualitas tuna loin juga dikenali dari fitur lemak, warna dan tekstur daging tuna. Fitur lemak diakuisisi menggunakan sensor *near infrared AS-7263*. Fitur warna tuna loin di akuisisi menggunakan *web camera* digital, selanjutnya dilakukan *pre-processing* citra dari ruang warna RGB ke HSV dan kemudian dinormalisasi. Fitur tekstur daging tuna diakuisisi dengan algoritma *gray level co-occurrence matrix*. Selanjutnya semua fitur digabungkan dan di *training* menggunakan algoritma *deep learning neural network*. Hasil pelatihan menghasilkan bobot terbaik, dan yang dipilih dari tingkat *error* terkecil. Loin yang digunakan sebagai data uji, selanjutnya diakuisi dari fitur bau, fitur citra warna, fitur tekstur dan fitur lemak, dan menghasilkan fitur gabungan data uji. Fitur uji masuk ke dalam kelas *grading* apabila memiliki derajat *similarity* yang paling dekat dengan salah satu bobot terbaik. Pengujian akurasi sistem menggunakan *confusion matrix*.

Penelitian ini juga menggunakan algoritma *K-Nearest Neighbor* untuk proses klasifikasi. Algoritma *Nearest Neighbor* sebagai salah satu algoritma *machine learning* yang paling sederhana berdasarkan teknik *supervised learning* yang mengasumsikan kesamaan antara data uji dengan data fitur yang tersedia dan memasukkan data uji ke dalam kategori yang paling mirip dengan kategori yang tersedia. Algoritma k-NN menyimpan semua data yang tersedia dan mengklasifikasikan titik data uji berdasarkan kesamaan / jarak terdekat. Selanjutnyaunjuk kerja klasifikasi kedua metode tersebut dapat dibandingkan. Hal ini bertujuan untuk mengetahui adanya kemungkinan dengan metode klasifikasi yang lebih sederhana tetap dapat memiliki unjuk kerja klasifikasi yang baik.

## 1.2 Rumusan Masalah

Berdasarkan latar belakang yang diuraikan diatas, yang menjadi permasalahan dalam penelitian ini adalah bagaimana membangun alat untuk mengenali kualitas *grade* tuna loin dengan mengakuisisi karakteristik bau, warna, tekstur dan kandungan lemak daging tuna (loin), dan bagaimana melakukan penentuan kualitas *grade* tuna loin berdasarkan fitur yang diperoleh dengan membandingkan metode *deep learning neural network* dan metode *k-Nearest Neighbors* untuk proses klasifikasi.

### 1.3 Tujuan

Tujuan penelitian ini adalah membangun alat untuk mengakuisisi karakteristik tuna loin dari bau, warna, tekstur dan kandungan lemak tuna loin untuk penentuan kualitas *grade* tuna loin dan mengetahui cara untuk mengenali kualitas *grade* tuna loin berdasarkan fitur yang diperoleh dengan membandingkan metode *deep learning neural network* dan metode k-NN untuk klasifikasi.

### 1.4 Manfaat Penelitian

Adapun manfaat penelitian adalah melalui alat yang dibangun dapat membantu dalam penentuan kualitas *grade* tuna loin berdasarkan karakteristik daging tuna menggunakan algoritma *neural network* dan *k-NN*, menghemat biaya bagi perusahaan dari sisi sumber daya manusia, sehingga penentuan kualitas daging tuna dapat lebih akurat.

### 1.5 Batasan Penelitian

Adapun batasan penelitian ini sebagai berikut

- a) Produk yang diteliti adalah produk loin tuna dari spesies sirip kuning (*yellowfin tuna*) yang ditangkap di wilayah perairan Maluku dan Maluku Utara. Hal ini disebabkan ikan tuna sirip kuning tersebar di beberapa wilayah perairan tersebut (Firdaus, 2019) (Simanjuntak et al., 2019) (C. J. Lintang et al., 2012)
- b) Menggunakan sensor gas MQ-4, MQ-136 dan MQ-137 untuk ekstraksi ciri bau tuna loin berdasarkan kandungan gas *methane*, *hydrogen sulfide* dan *amoniak*, yang dirangkai dengan *Ardunio Uno ATMega328P*. Sensor gas ini dipilih dengan pertimbangan biaya yang murah dan cukup handal untuk mengenali level bau *amoniak* dan gas *methan*(ShowRange, n.d.), dimana tingkat kesegaran ikan terkait dengan kandungan *amoniak*, asam sulfat dan gas *methan*(Pusdik.kkp.go.id, 2019)
- c) Akuisisi citra obyek yang diteliti menggunakan *web camera* digital CAMTECH CT50 1440P 2K 4MP
- d) Grade loin dibagi menjadi 4 grade yaitu *grade #1*, *grade #2+*, *grade #2*, *grade #3* (DiGregorio, 2012)(Gourmets, 2021)

- e) Akuisisi fitur kandungan lemak tuna loin menggunakan metode *spectroscopy* dengan menggunakan sensor *near infrared spectroscopy*. (Buniyamin et al., 2011) (Khodabux et al., 2007)

### **1.6 Kebaharuan Penelitian (*Novelty*)**

Penelitian dan publikasi sebelumnya lebih banyak meneliti penentuan kesegaran ikan menggunakan metode klasifikasi *neural network* dan sudah ada penelitian mengenali *grade* ikan tuna berdasarkan citra menggunakan *color histogram* dan tekstur menggunakan *gray level co-occurrence matrix* dengan klasifikasi dengan mengelompokkan ke dalam *grade* A, B dan D menggunakan algoritma *Support Vector Machine*. Kebaruan penelitian ini yaitu belum ada penelitian berdasarkan bau, warna, tekstur dan kandungan lemak untuk menentukan kualitas grade tuna loin (DiGregorio, 2012) dan alat yang dibangun dapat menemukan nilai referensi sebagai *best practice* dalam penentuan kualitas tuna loin dan alat yang dibangun dapat memperkaya pengenalan fitur dari alat *E-Nose* yang sudah ada saat ini.

## **BAB II**

### **TINJAUAN PUSTAKA**

Teknologi informasi membantu mengelola data produk perikanan melalui pencatatan data distribusi ikan dan pencatatan kualitas ikan. Penentuan kualitas ikan diperlukan karena kualitas dan keamanan produk sebagai hal yang penting bagi konsumen, semakin baik kualitas produk maka harga jual produk semakin baik(Sidik et al., 2013).

#### **2.1 State of The Art**

Penelitian dari Catur Pramono Adi (2021) mengenai pembuatan prototipe penentu kesegaran ikan patin berbasis *sensor TCS 230*. Prototipe berupa alat untuk mengetahui tingkat kesegaran ikan patin berdasarkan tingkat warna daging menggunakan ruang warna RGB (*red, green* dan *blue*). Prototipe ini dibangun menggunakan mikrokontroler *Arduino Atmega 2560*, yang dihubungkan dengan sensor TCS 230 yang berfungsi untuk mendeteksi warna berdasarkan nilai *red, green* dan *blue*, kemudian dirangkaikan dengan LCD 20×4 untuk menampilkan hasil deteksi kesegaran ikan. Sasis berbentuk kubus dengan bahan besi ringan serta papan yang mampu menahan air yang mudah dibersihkan. Prototipe ini mempunyai dimensi panjang 28 cm, lebar 25 cm, dan tinggi 18 cm. Cara penggunaannya yaitu ikan patin dimasukan ke dalam kubus yang terpasang sensor TCS 230 yang kemudian sensor mendeteksi warna daging, setelah itu citra di konversi dalam nilai RGB. Arduino mengklarifikasi pembacaan sensor yang kemudian diteruskan ke LCD sebagai luaran hasil uji. Berdasarkan hasil pengujian data *confusion matrix*, prototipe ini memiliki nilai akurasi data sebesar 80%, tingkat presisi positif sebesar 83%, dan presisi negatif sebesar 67%. Berdasarkan hasil pengujian, prototipe deteksi kesegaran ikan patin menghasilkan persentase keberhasilan sebesar 84,4 % (Catur Pramono Adi et al., 2021).

Penelitian dari Prasetyo (2021) mengenai penerapan *Convolution Neural Network* untuk klasifikasi kesegaran ikan bandeng berdasarkan citra mata. Deteksi kesegaran dengan menyentuh tubuh ikan dapat mengakibatkan kerusakan tanpa disengaja, maka deteksi kesegaran ikan harus dilakukan tanpa menyentuh ikan bandeng dengan menganalisa citra dari mata ikan. Pada penelitian ini kesegaran ikan

bandeng dikategorikan ke dalam dua kelas yaitu sangat segar dan tidak segar dari citra mata ikan, dengan membandingkan metode *transfer learning* dari empat metode *Convolutional Neural Network*, yaitu *Xception*, *MobileNet V1*, *Resnet50*, dan *VGG16*. Hasil eksperimen klasifikasi dua kelas kesegaran ikan bandeng menggunakan 154 citra menunjukkan bahwa *VGG16* mencapai kinerja terbaik dibanding arsitektur lainnya, dengan akurasi klasifikasi mencapai 0.97. Dengan akurasi yang lebih tinggi dibanding arsitektur lainnya maka *VGG16* relatif lebih tepat digunakan untuk klasifikasi dua kelas kesegaran ikan bandeng (Prasetyo et al., 2021).

Penelitian dari Naimullah (2020) mengenai klasifikasi *grade* daging tuna berdasarkan fitur warna dan tekstur menggunakan histogram warna dan *gray level co-occurrence matrix*. Citra daging tuna di *pre-processing* dan citra ruang warna RGB di konversi ke citra ruang warna HSV, selanjutnya di normalisasi histogram. Kelas *grade* daging tuna dibagi menjadi 3 kelas yaitu *grade A*, *grade B* dan *grade D*. Fitur citra ruang warna RGB dilatih dan fitur citra HSV dilatih dengan algoritma SVM (*support vector machine*), dan selanjutnya sampel di *pre-processing* dan klasifikasi dilakukan menggunakan algoritma SVM. Hasil menunjukkan bahwa citra RGB yang dikonversi ke ruang warna HSV menunjukkan unjuk kerja yang lebih baik. Klasifikasi menggunakan algoritma *Support Vector Machine* dengan hasil 81.6% dari 36 data yang terdiri dari 13 *grade A*, 11 *grade B*, dan 12 *grade D* (Naimullah et al., 2020).

Penelitian dari Fitriyah (2020) mengenai deteksi kesegaran ikan tongkol (*Euthynnus Affinis*) secara otomatis berdasarkan citra mata menggunakan *binary similarity*. Deteksi tingkat kesegaran ikan tongkol menggunakan fitur citra mata ikan. Ikan segar memiliki pupil bulat berwarna hitam yang utuh dan jernih di tengahnya. Hal tersebut kemudian dijadikan *knowledge-based* dari proses deteksi kesegaran ikan. Sebelum dilakukan proses deteksi, dilakukan proses *pre-processing* untuk mendapatkan gambar kepala ikan secara otomatis. Selanjutnya dihitung *similarity* antara citra biner kepala ikan dengan 2 buah *template*, yakni *template* mata untuk mendeteksi mata dan *template* tengah untuk mendeteksi bulat hitam di tengah mata. Sebanyak 30 citra mata ikan dengan kriteria segar dan tidak segar digunakan sebagai data pengujian. Dari pengujian, kedua *template* tersebut mampu membedakan ciri morfologis dari mata ikan yang segar dengan tepat (Fitriyah et al., 2020).

Penelitian dari Amongsari (2020) mengenai pengembangan sensor kesegaran *edible* untuk *fillet* ikan tuna (*Thunnus Albacares*) berbasis antosianin kulit buah juwet (*Syzygium Cumini*) dengan membran *selulosa bacterial*. Penelitian ini mengembangkan sensor kesegaran *edible* berbasis indikator antosianin dari ekstrak kulit buah juwet (*Syzygium Cumini*) dengan membran selulosa bakterial *nata de coco*. Sensor kesegaran *edible* tersebut dapat diaplikasikan sebagai sensor kesegaran dan mengetahui tingkat kesegaran *fillet* ikan tuna dengan berbagai parameter. Uji parameter kesegaran *fillet* ikan tuna meliputi uji total mikroba, uji total *volatile bases nitrogen* (TVB-N), nilai pH, nilai tekstur, dan uji organoleptis. Perubahan warna sensor kesegaran *edible* diamati secara visual dan diuji menggunakan program *ImageJ* untuk menentukan nilai *mean* warna hijau. Hasil menunjukkan warna sensor kesegaran berubah menjadi warna ungu tua saat *fillet* ikan tuna dalam keadaan segar, ungu muda saat *fillet* ikan tuna masih agak segar dan abu-abu ketika fillet ikan tuna sudah tidak lagi segar. Nilai *mean* warna hijau sensor kesegaran *edible* meningkat seiring dengan penurunan tingkat kesegaran *fillet* ikan tuna (Amongsari et al., 2020).

Penelitian dari Taheri-Garavand (2020) mengenai pendekatan berbasis *smart deep learning* untuk diagnosis kesegaran non-destructive dari ikan mas. Deteksi kesegaran ikan yang baru dan akurat dari fitur citra ikan mas, diklasifikasikan menggunakan algoritma *convolutional neural network*. Untuk mengklasifikasikan citra ikan untuk mendagnosis kesegaran, tahap awal menggunakan arsitektur *VGG-16* untuk mengekstraksi fitur dari citra ikan secara otomatis. Selanjutnya dibentuk *classifier block* dari *layer dropout* dan *dense layers* untuk mengklasifikasikan citra ikan. Hasil yang diperoleh menunjukkan akurasi klasifikasi sebesar 98,21%. Hasil penelitian menunjukkan metode berbasis *Convolutional Neural Network* (CNN) yang diusulkan memiliki kompleksitas yang lebih rendah dengan akurasi yang lebih tinggi dibandingkan dengan metode klasifikasi tradisional. Metode CNN mampu memantau dan mengklasifikasikan kesegaran ikan sebagai teknik yang cepat, murah, tepat, tidak merusak, *real-time* dan otomatis (Taheri-Garavand et al., 2020).

Penelitian dari Kumar (2020) mengenai metode desain sistem cerdas untuk klasifikasi kesegaran ikan secara *real time* menggunakan *artificial neural network*. Penelitian ini mengakuisisi data kesegaran ikan menggunakan sensor *array* yang terhubung dengan *Arduino Uno* yaitu dengan sensor gas *array* MQ (MQ-4, MQ-2, MQ

8, MQ-7, MQ-5 dan MQ-135). Data dikumpulkan dari 3 spesies yaitu ikan nila, ikan *carpio* dan ikan *tengra* selama beberapa hari. Fitur yang di ekstraksi berupa deretan nilai kandungan gas yang dideteksi dari sensor *array*. Fitur yang diperoleh dari banyak sampel dilatih menggunakan jaringan syaraf tiruan, sedangkan pengujian dilakukan hanya dengan menggunakan data ikan segar (hari 1), semi-segar (hari 2) dan ikan rusak (hari 3) dengan menggunakan 9 sampel dari tiga *spesies* berbeda. Seluruh sampel uji diklasifikasikan dengan akurasi 99%. *Output* klasifikasi menghasilkan nilai *MSE*  $1.4155 \times 10^{-17}$  pada 9022 epoh untuk spesies *tilapia*, *MSE*  $5.9805 \times 10^{-13}$  pada 9448 epoh untuk species *carpio* dan *MSE*  $5.925 \times 10^{-18}$  pada 10000 epoh untuk spesies *tengra* (Kumar & Kumar, 2020).

Penelitian dari Pei Li (2019) untuk membedakan kualitas tepung ikan berdasarkan karakteristik yang berbeda menggunakan teknologi *electronic nose*. *Electronic nose* portabel digunakan untuk mendeteksi dan mengklasifikasikan tepung ikan dengan kualitas berbeda. Penelitian ini menyajikan analisis SPME-GC-MS (mikroekstraksi gas kromatografi masa fase padat) tepung ikan dan melakukan pemilihan fitur asli sebelum dilakukan pemrosesan. Parameter yang digunakan adalah nilai integral, nilai energi *wavelet*, nilai *gradien* maksimum, nilai diferensial rata-rata, nilai rata-rata respons keadaan tunak dan nilai varians untuk mempelajari sampel tepung ikan dengan nilai waktu penyimpanan yang berbeda. Metode klasifikasi yang digunakan adalah *Principal Component Analysis* (PCA) dan *Linear Discriminant Analysis* (LDA), dan lima metode klasifikasi yaitu *multilayer perceptron*, *random forest*, algoritma *k-nearest neighbors*, *support vector machine*, dan klasifikasi *Bayesian*. Hasil penelitian menunjukkan bahwa metode klasifikasi *random forest* memiliki tingkat akurasi tertinggi untuk algoritma klasifikasi. Tingkat akurasi tertinggi untuk membedakan sampel tepung ikan dengan kualitas yang berbeda dicapai dengan menggunakan nilai integral, nilai stabil, dan nilai diferensial rata-rata. Tingkat akurasi terendah untuk membedakan sampel tepung ikan dengan kualitas yang berbeda dicapai dengan menggunakan nilai gradien maksimum. Temuan ini menunjukkan bahwa *electronic nose* dapat mengidentifikasi sampel tepung ikan dengan waktu penyimpanan yang berbeda (Li et al., 2019).

Penelitian dari Lielei Wu (2019) melakukan *review* beberapa teknik baru dalam mengevaluasi atribut kualitas kesegaran ikan, dari tinjauan penelitian sebelumnya.

Penelitian ini meninjau prinsip dan aplikasi teknik baru seperti teknik biosensor enzim, biosensor elektrokimia, *electronic nose*, sensor kolorimetri, *electronic tongue*, teknik *computer vision*, spektroskopi Vis/NIR, spektroskopi HSI dan spektroskopi fluoresensi sebagai teknik yang handal dan cepat yang mengembangkan teknik tradisional yang memiliki proses yang lama, mahal dan rumit. Beberapa teknik diatas memiliki keunggulan yaitu hemat waktu, cepat, ekonomis, dan dapat mendeteksi kesegaran ikan secara *online* dan tidak merusak sampel. Tantangan ke depan yaitu mengoptimalkan dan menyederhanakan teknik *bionik*, mengembangkan algoritma dan *chemometrics* spektroskopi dan meningkatkan selektivitas dan sensitivitas biosensor (Wu et al., 2019).

Penelitian dari Navotas (2018) mengembangkan aplikasi yang secara otomatis mengidentifikasi tiga ikan yang paling banyak dikonsumsi di Filipina, yaitu bandeng, layang bulat, dan nila. Melalui pengolahan citra, aplikasi mengklasifikasikan kesegaran ikan dari level 1 (basi) hingga level 5 (segar) dengan menggunakan nilai RGB mata dan insang serta menentukan sisa umur simpannya. Perangkat lunak ini dikembangkan dengan pembelajaran iteratif jaringan saraf umpan maju dengan 30 sampel ikan per spesies yang digunakan untuk mendapatkan total 800 gambar masing-masing untuk mata dan insang. Setiap jenis ikan memiliki nilai RGB yang berbeda dari tiap kelasnya sehingga 3 metode *feed forward neural networks* digunakan untuk klasifikasi kesegaran ikan. Agar diperoleh citra dengan kualitas baik, diperlukan iluminasi yang konstan dan sumber cahaya yang baik saat akuisisi citra di dalam tabung/wadah. Pengolahan citra menggunakan metode *feed forward neural neworks* dengan menggunakan *software Matlab*. Hasil penelitian menunjukkan bahwa perangkat memberikan hasil yang dapat diterima dalam mengidentifikasi ikan dan dalam menentukan kesegarannya (Navotas et al., 2018).

Penelitian dari Sengar (2017) meneliti tentang teknik *computer vision* untuk mengidentifikasi kualitas ikan setelah terpapar pestisida, menyatakan kualitas ikan dipengaruhi oleh penanganan ikan, penyimpanan, paparan kontaminan dan perubahan iklim. Terdapat perbedaan kualitas antara ikan yang dipelihara di air tawar dengan yang tercemar atau air yang terkena pestisida. Identifikasi dan deteksi kontaminasi pestisida pada ikan membutuhkan sejumlah perangkat mahal dan tenaga ahli. Penelitian ini menyajikan metode komputer non-destruktif untuk mengidentifikasi

perbedaan kualitas antara ikan yang terpapar pestisida dan ikan air tawar. Metode yang digunakan adalah citra jaringan mata ikan di ekstraksi untuk mendapatkan berbagai fitur dengan domain spasial. Fitur statistik dipilih dalam domain spasial dan fitur di analisis untuk mendapatkan variasi diskriminatif citra strategis. Fitur yang di analisis ini berkorelasi dengan ikan yang terpapar pestisida dan ikan air tawar, di proses menggunakan algoritma *machine learning*. Hasil percobaan menggambarkan efisiensi metode yang diusulkan dan akurasi identifikasi 96,87% dengan waktu komputasi lebih sedikit, dapat digunakan untuk penilaian kualitas ikan(Sengar et al., 2017).

Penelitian dari Najib (2016) yang meneliti kualitas ikan menggunakan *odor*(bau) dengan teknik *Case Based Reasoning*, memastikan kualitas ikan untuk menghindari keracunan makanan. Terdapat tiga metode untuk mengetahui kualitas ikan yaitu metode sensorik, mikrobiologi dan kimia. Saat ini, beberapa penjual ikan menggunakan formalin untuk membuat ikan terlihat segar dan bagus. Formalin adalah zat kimia gas formaldehida yang dilarutkan dalam air, berbau tajam tidak berwarna yang biasa digunakan dalam industri tekstil, plastik, kertas, cat, konstruksi. Untuk membedakan ikan segar tanpa formalin dan ikan dengan formalin cukup sulit karena dari sisi tampilan terlihat segar dan bagus tetapi yang berbeda dari bau yaitu ikan segar masih berbau amis sedangkan ikan berformalin tidak berbau. Sehingga penelitian menggunakan *electronic nose (E-nose)* untuk mengetahui ikan segar dan ikan diawetkan berbahan dasar formalin. *E-nose* terdiri dari *array* sensor kimia konduktometri yang mengubah resistansi saat terkena uap. Profil bau dari sampel ikan dikumpulkan berdasarkan prosedur eksperimental yang ditentukan. Data mentah yang di ukur kemudian disimpan di Microsoft Excel dan diproses pada software MATLAB. Selanjutnya data melalui proses normalisasi dan fitur uniknya di ekstraksi menggunakan statistik. Fitur input dimasukkan ke dalam *library Case-Based Reasoning (CBR)* dan diklasifikasikan secara cerdas menggunakan metode CBR dan kinerja model klasifikasi di validasi. Hasil penelitian menunjukkan bahwa klasifikasi dengan metode CBR memiliki akurasi 100% (Najib et al., 2016).

Penelitian dari Eka Putra (2016) yang mengklasifikasikan citra menggunakan *Deep Learning Convolutional Neural Network (CNN)*. Metode CNN terdiri dari dua tahap yaitu tahap pembelajaran dengan metode *backpropagation* dan klasifikasi citra menggunakan *feedforward*. Sebelum proses klasifikasi, terlebih dahulu dilakukan *pre-*

*processing* citra dengan metode *wrapping* dan *cropping* untuk memfokuskan objek yang akan diklasifikasi. Selanjutnya dilakukan *training* menggunakan metode *feed forward* dan *backpropagation*. Setelah proses *training* selanjutnya tahap klasifikasi menggunakan metode *feed forward* dengan bobot dan bias yang diperbarui. Unjuk kerja diukur dengan *confusion matrix* menggunakan basis data *Caltech 101*, dan diperoleh sistem dapat melakukan klasifikasi citra dengan baik (Eka Putra, 2016).

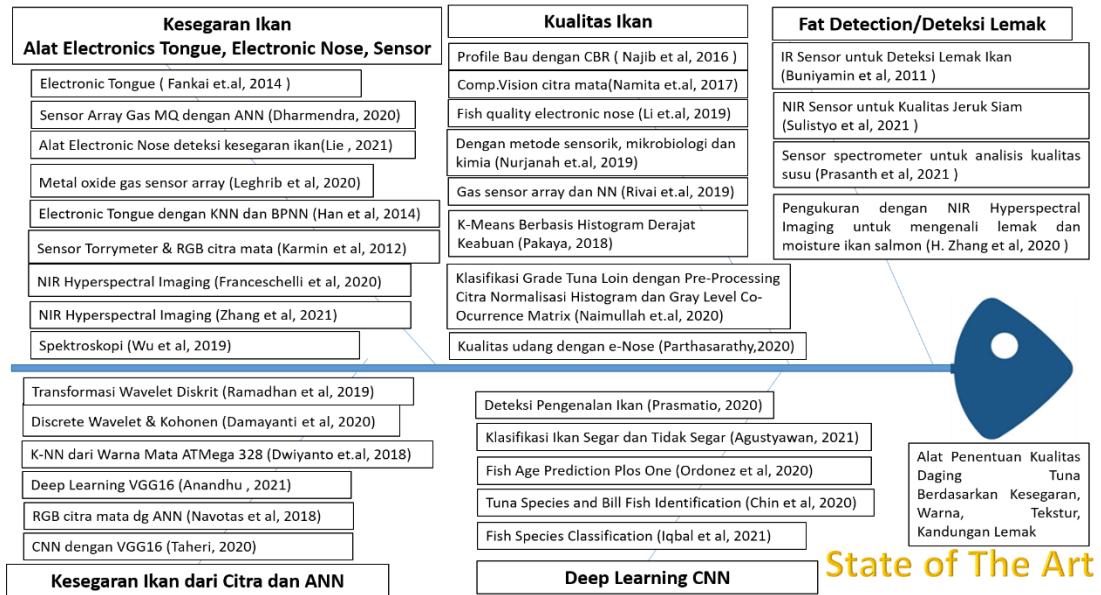
Penelitian dari Nugroho (2020) yang meneliti penentuan ekspresi wajah manusia melalui implementasi *deep learning* menggunakan *convolutional neural network*. CNN memiliki beberapa lapisan (*layer*) yang mengekstraksi informasi dari citra dan menentukan klasifikasi dari citra berupa skor klasifikasi. Aplikasi ini menggunakan bahasa pemrograman *python*, web berbasis *flask*, *tensorflow*, dan *opencv*. Tahapan penentuan ekspresi wajah yang melalui 2 tahap yaitu tahap *pre-processing*, dan tahap klasifikasi. Proses *training* dilakukan dengan menggunakan *batch size*, dan epoh yang berbeda-beda untuk mendapatkan model terbaik. Dataset terdiri dari ekspresi senang, sedih, takut, jijik, netral, marah, dan kaget. Jumlah dataset tidak sepenuhnya mempengaruhi nilai akurasi, tetapi kedetailan citra untuk digunakan sebagai dataset pelatihan sangat mempengaruhi hasil akurasi. Dengan epoh 100, *batch size* 128 didapatkan hasil akurasi training sebesar 90% dan validasi sebesar 65%. Hasil percobaan dari total 35 ekspresi, 28 ekspresi berhasil ditebak dengan benar dengan mendapatkan akurasi sebesar 80% (Nugroho et al., 2020).

Penelitian dari Astutik (2015) mengenali kualitas induk gurame, berdasarkan tekstur kulit sisik dengan ekstraksi fitur menggunakan gabungan dua metode yaitu alihragam *wavelet haar* dan *Principle Component Analysis* (PCA). Untuk mengenali jenis induk gurame menggunakan ekstraksi fitur histogram HSV, proses klasifikasi menggunakan *k-Nearest Neighbors* (k-NN). Data yang digunakan adalah citra ikan gurame yang terdiri dari 56 buah foto untuk penentuan kualitas gurame, 56 buah citra warna dasar sirip gurame untuk mengenali jenis ikan gurame. Ekstraksi ciri menggunakan metode ekstraksi *wavelet* PCA dan hasil klasifikasi menggunakan algoritma k-NN, diperoleh rata-rata akurasi sebesar 97,8%. Hasil klasifikasi dengan k-NN menghasilkan total rata-rata akurasi sebesar 98,8% dengan menggunakan metode ekstraksi *wavelet* tanpa PCA. Nilai akurasi klasifikasi dengan metode k-NN untuk

mengenali jenis jantan atau betina induk gurame diperoleh sebesar 89,5% dengan menggunakan metode histogram HSV (Astutik, 2015).

Penelitian dari Fangkai Han (2014) melakukan penentuan kesegaran ikan secara non destruktif menggunakan *electronic tongue* yang dikombinasikan dengan algoritma *multivariate linear* dan *non-linear*. *E-nose* yang digabungkan dengan algoritma multivariat linier dan non-linier dicoba untuk mengatasi kelemahan deteksi kesegaran ikan. Penelitian ini menggunakan sampel ikan *parabramis pekinensis* yang disimpan pada suhu 4°C, dan mengukur total nitrogen dasar (TVB-N) dan jumlah total TVC dari sampel. Selanjutnya algoritma analisis diskriminan *Fisher LDA* dibandingkan dengan *support vector machine* (SVM) untuk mengklasifikasikan sampel yang disimpan pada hari yang berbeda. Hasil penelitian menunjukkan bahwa model SVM lebih baik daripada model *Fisher LDA* dengan tingkat identifikasi lebih tinggi yaitu 97,22%. Algoritma *partial least square* (PLS) dan *support vector regression* (SVR) dibandingkan untuk memprediksi nilai TVB-N dan TVC. Model tersebut di evaluasi dengan algoritma prediksi *root mean square error* (RMSEP) dan prediksi koefisien korelasi (Rpre). Hasil penelitian menunjukkan bahwa model SVR lebih unggul dibandingkan model PLS dengan RMSEP = 5,65 mg/100 g, Rpre = 0,9491 untuk prediksi TVB-N dan RMSEP = 0,73 log CFU/g, Rpre = 0,904 untuk memprediksi TVC. Studi ini menunjukkan bahwa *electronic tongue* dengan algoritma *support vector machine* (SVM) dan *support vector regression* (SVR) mampu mendekripsi kesegaran ikan lebih baik dan tidak merusak kondisi ikan (F. Han et al., 2014).

Berdasarkan sejumlah penelitian terkait yang telah dilakukan sebelumnya, maka digambarkan *fishbone state of the art* penelitian. Gambar 2.1 menggambarkan *fishbone state of the art* penelitian yang terkait dengan kualitas ikan.

Gambar 2.1 *Fishbone State of the Art* Penentuan Kualitas Ikan

Tabel 2.1. Rangkuman Penelitian Sebelumnya

No	Penulis	Judul Penelitian	Metode	Media
1	(Massaro et al., 2021)	<i>New strategies for the differentiation of fresh and frozen/thawed fish: A rapid and accurate non-targeted method by ambient mass spectrometry and data fusion (part A)</i>	Spektrometri massa ambien (AMS) untuk ekstraksi fitur, dan fitur di training dengan algoritma SVM dan sampel ikan diklasifikasikan dari ikan segar atau ikan yang sebelumnya beku	Perangkat AMS dan computer
2	(Massaro et al., 2021)	<i>Freshness analysis based on lipidomics for farmed Atlantic salmon (<i>Salmo salar L.</i>) stored at different times</i>	<i>Liquid chromatography-mass spectrometry</i> untuk mempelajari perubahan lemak pada ikan salmon, hubungan komposisi lemak dan kesegaran ikan salmon pada waktu simpan yang berbeda	Komputer, perangkat chromatography mass spectrometry
3	(Francesc helli et al., 2021)	<i>Sensing technology for fish freshness and safety: A review</i>	Teknik instrumental non-invasif dan non-destruktif, seperti biosensor, <i>e-sensor</i> , dan metode spektroskopi	Komputer

No	Penulis	Judul Penelitian	Metode	Media
4	(Li et al., 2021)	<i>Quantitative analysis of fish meal freshness using an electronic nose combined with chemometric methods</i>	<i>electronic nose</i> untuk mendeteksi bau kandungan <i>Total volatile basic nitrogen</i> (TVB-N) dan <i>acid value</i> (AV). TVB-N dan AV pada daging ikan. Dilatih dengan metode <i>random forest regression</i> (RFR) dan model <i>least squares support vector machine</i> (LSSVM) berdasarkan algoritma <i>particle swarm optimization</i> (PSO)	<i>Electronic Nose</i> , Komputer
5	(Suresh et al., 2021)	<i>Fish Freshness Identification Using Deep Learning</i>	Menggunakan algoritma CNN jaringan VGG-16 melalui <i>transfer learning</i> dari citra mata, citra insang dan fitur warna kulit ikan	Komputer
6	(Cui & Cui, 2021)	<i>Non-destructive evaluation of salmon and tuna freshness in a room-temperature incubation environment using a portable visible/near-infrared imaging spectrometer</i>	<i>Deteksi kesegaran ikan salmon dan tuna</i> menggunakan spektrometer <i>imaging visible / near infrared</i> dengan algoritma CNN	Alat spectrometer dan komputer
7	(Lan et al., 2021)	<i>Evaluation of quality changes in big-eye tuna (<i>Thunnus obesus</i>) based on near-infrared reflectance spectroscopy (NIRS) and low field nuclear magnetic resonance (LF-NMR)</i>	Spektroskopi <i>near infrared</i> (NIRS) dan <i>low field nuclear magnetic resonance</i> (LF-NMR) untuk mengevaluasi perubahan kualitas <i>big eye tuna</i>	Perangkat sensor NIRS dan komputer
8	(W. Zhang et al., 2021)	<i>Rapid evaluation of freshness of largemouth bass under different thawing methods using hyperspectral imaging</i>	<i>Hyperspectral imaging</i> (HSI) dan <i>data multivariat</i> untuk mengidentifikasi kesegaran ikan. Algoritma MLSR dan PLSR untuk memprediksi seluruh spektrum	Komputer

No	Penulis	Judul Penelitian	Metode	Media
9	(Medeiro s et al., 2021)	<i>Computer Vision and Machine Learning for Tuna and Salmon Meat Classification</i>	Klasifikasi daging tuna dan salmon menggunakan computer vision dan machine learning	Komputer
10	(Sulistyo et al., 2021)	<i>Handheld arduino-based near infrared spectrometer for non-destructive quality evaluation of siamese oranges</i>	<i>Near infrared spectrometer sensor, Arduino programming</i>	<i>Infrared sensor and computer</i>
11	(Prasetyo et al., 2021)	Perbandingan Convolution Neural Network untuk Klasifikasi Kesegaran Ikan Bandeng Pada Citra Mata	Klasifikasi kesegaran ikan bandeng pada citra mata	Komputer
12	(Agustya wan, 2021)	Pengolahan Citra untuk Membedakan Ikan Segar dan Tidak Segar Menggunakan Convolutional Neural Network	Klasifikasi citra ikan dengan Convolutional Neural Network (CNN)	Komputer
13	(Sholihin, 2021)	Identifikasi Kesegaran Ikan Berdasarkan Citra Insang dengan Metode Convolution Neural Network	Identifikasi kesegaran ikan dari citra insang dengan CNN	Komputer
14	(Taheri-Garavand et al., 2020)	<i>Smart Deep Learning-Based Approach for Non-Destructive Freshness Diagnosis of Common Carp Fish</i>	Akuisi citra ikan dan pelatihan dengan arsitektur VGG-16 untuk fitur dari citra ikan	Komputer
15	(Kumar & Kumar, 2020)	<i>An Intelligent System for Fish Freshness Quality Assessment using Artificial Neural Network</i>	Akuisisi data dengan sensor array gas dan menggunakan Artificial Neural Network untuk klasifikasi kualitas ikan	Sensor Gas dan Komputer
16	(Lalabadi et al., 2020)	<i>Fish Freshness Categorization from Eyes and Gills Color Features using Multiclass Artificial Neural Network and Support Vector Machines</i>	Citra mata dan insang dalam durasi penyimpanan, ekstraksi citra warna RGB, HSV, dan L*a*b*. Pelatihan dengan algoritma SVM	Komputer

No	Penulis	Judul Penelitian	Metode	Media
17	(Qin et al., 2020)	<i>Inspecting Species and Freshness of Fish Fillets using Multimode Hyperspectral Imaging Techniques</i>	Teknik <i>hyperspektral multimode</i> untuk memeriksa spesies dan kesegaran ikan <i>fillet</i>	Alat <i>multimode hyperspectral imaging</i> dan komputer
18	(Moon et al., 2020)	<i>Evaluation of Salmon, Tuna, and Beef Freshness using a Portable Spectrometer</i>	Evaluasi kesegaran ikan dan daging menggunakan <i>spektrometer dan algoritma CNN</i>	Alat spektrometer dan komputer
19	(Rahmawati et al., 2020)	Implementasi Sensor Gas MQ-136 dan MQ-137 untuk Mendeteksi Kesegaran Daging Sapi Menggunakan Metode <i>Neural Network</i>	Deteksi kesegaran daging sapi dengan sensor gas MQ 136 dan 137 dan metode <i>neural network</i>	Sensor gas dan komputer
20	(Fitriyah et al., 2020)	Deteksi Kesegaran Ikan Tongkol ( <i>Euthynnus Affinis</i> ) Secara Otomatis Berdasarkan Citra Mata Menggunakan <i>Binary Similarity</i>	Deteksi kesegaran ikan dengan citra mata dengan <i>binary similarity</i>	Komputer
21	(Nugroho et al., 2020)	Implementasi <i>Deep Learning</i> Menggunakan <i>Convolutional Neural Network</i> (CNN) Pada Ekspresi Manusia	Pengenalan ekspresi manusia dengan klasifikasi citra metode CNN	Komputer
22	(Lu et al., 2020)	<i>Identifying The Species of Harvested Tuna and Billfish using Deep Convolutional Neural Networks</i>	Identifikasi spesies tuna dan <i>billfish</i> dengan <i>Deep Learning CNN</i>	Komputer
23	(Ordoñez et al., 2020)	<i>Explaining Decisions of Deep Neural Networks used for Fish Age Prediction</i>	CNN untuk memprediksi usia ikan dari citra <i>otolith</i>	Komputer
24	(Franceschelli et al., 2020)	<i>Vis/NIR Hyperspectral Imaging to Assess Freshness of Sardines (<i>Sardina Pilchardus</i>).</i>	Kesegaran sardines menggunakan kamera <i>Vis/NIR Hyperspectral</i>	Komputer

No	Penulis	Judul Penelitian	Metode	Media
25	(Anvy et al., 2020)	<i>Clustering of Fish Freshness using Discrete Wavelet Transform and Kohonen Self Organizing Map</i>	Klasifikasi kesegaran ikan dengan transformasi <i>wavelet</i> diskrit dan <i>Kohonen Self Organizing Map</i> (SOM)	Komputer
26	(Leghrif et al., 2020)	<i>Assessing the Freshness of Agadir Blue Fish using a Metal Oxide Gas Sensing Array</i>	Deteksi kesegaran ikan dengan <i>array sensor gas metal oxide</i>	Komputer, sensor
27	(Prasmati o et al., 2020)	Deteksi dan Pengenalan Ikan Menggunakan Algoritma <i>Convolutional Neural Network</i>	Klasifikasi ikan dengan <i>deep learning CNN</i>	Komputer
28	(Khansa, 2020)	Penerapan Ekstraksi Ciri Transformasi Wavelet dalam Pembuatan Model Klasifikasi	Klasifikasi kesegaran ikan menggunakan k-NN	Komputer
29	(H. Zhang et al., 2020)	<i>Non-destructive Determination of Fat and Moisture Contents in Salmon (<i>Salmo salar</i>) Fillets using Near-Infrared Hyperspectral Imaging Coupled with Spectral and Textural Features</i>	NIR <i>hyperspectral imaging</i> , dan akuisisi tekstur dengan algoritma <i>Gray Level Co-occurrence Matrix (GLCM)</i>	<i>Hyperspectral fotometer, computer</i>
30	(Khansa, 2020)	Penerapan Ekstraksi Ciri Transformasi Wavelet dalam Pembuatan Model Klasifikasi	Klasifikasi kesegaran ikan menggunakan k-NN	Komputer
31	(Noviant o & Erawan, 2020)	Perbandingan Metode Klasifikasi pada Pengolahan Citra Mata Ikan Tuna	Klasifikasi citra mata dan tekstur dengan ANN, k-NN, dan SVM	Komputer
32	(Khoshnoudi-Nia & Nasab, 2019)	<i>Prediction of Various Freshness Indicators in Fish Fillets by One Multispectral Imaging System</i>	<i>Multispektral imaging system</i> untuk memprediksi kesegaran ikan <i>fillet</i>	Alat multispektral imaging dan computer

No	Penulis	Judul Penelitian	Metode	Media
33	(Li et al., 2019)	<i>Research on Distinguishing Fish Meal Quality using Different Characteristic Parameters Based on Electronic Nose Technology</i>	Akuisisi data <i>electronic nose Principal Component Analysis</i> (PCA) dan <i>Linear Discriminant Analysis</i> (LDA), untuk penentuan kualitas makanan <i>seafood</i> dengan algoritma MLP, <i>random forest</i> , k-NN, SVM, dan klasifikasi <i>Bayesian</i> .	Komputer
34	(Wu et al., 2019)	<i>Novel Techniques for Evaluating Freshness Quality Attributes of Fish: A Review of Recent Developments</i>	Menggunakan biosensor enzim, biosensor elektrokimia, hidung elektronik, sensor kolorimetri, <i>electronic nose</i> , <i>computer vision</i> , spektroskopi Vis/NIR, spektroskopi HSI dan spektroskopi fluoresensi	Komputer dan zat kimia
35	(Nurjannah et al., 2019)	<i>Fish Quality and Nutritional Assessment of Yellowfin Tuna (<i>Thunnus albacares</i>) During Low Temperature Storage</i>	Metode sensorik, mikrobiologi dan kimia untuk kualitas ikan tuna sirip kuning dan cakalang serta kualitas nutrisinya selama penyimpanan suhu beku tertentu	Mikrobiologi, Kimia
36	(Rivai et al., 2019)	<i>Fish Quality Recognition using Electrochemical Gas Sensor Array and Neural Network</i>	Penentuan kualitas ikan dengan sensor gas array elektrokimia dan algoritma <i>Neural Network</i>	Komputer
37	(Pramunedar et al., 2019)	<i>Fish Classification Based on Underwater Image Interpolation and Back-Propagation Neural Network</i>	Klasifikasi ikan berdasarkan <i>underwater image interpolation</i> dan BPNN	Komputer

No	Penulis	Judul Penelitian	Metode	Media
38	(Ramadh an & Setiyono, 2019)	Pengolahan Citra untuk Mengetahui Tingkat Kesegaran Ikan Menggunakan Metode Transformasi Wavelet Diskrit	Tingkat kesegaran ikan metode transformasi <i>wavelet</i> diskrit, segmentasi k-NN	Komputer
39	(Prayogi & Wibisono , 2019)	Implementasi Pengolahan Citra Digital Untuk Deteksi Kesegaran Ikan Menggunakan Perangkat Android	Deteksi kesegaran ikan bandeng dengan kernel RBF pada SVM	Komputer
40	(Prasanth et al., 2019)	<i>Development of a Low-Cost Portable Spectrophotometer for Milk Quality Analysis</i>	<i>Near infrared spectrometer sensor</i>	<i>Infrared sensor, computer</i>
41	(Navotas et al., 2018)	<i>Fish Identification and Freshness Classification Through Image Processing using Artificial Neural Network</i>	Akuisisi citra RGB, segmentasi, <i>training</i> dengan <i>Feed forward Neural Network</i>	Komputer
42	(Sun et al., 2018)	<i>Classifying Fish Freshness According to The Relationship Between EIS Parameters and Spoilage Stages</i>	Klasifikasi kesegaran ikan dengan <i>electrochemical impedance spectroscopy</i> (EIS)	Perangkat EIS dan computer
43	(Siddiqui et al., 2018)	<i>Automatic Fish Species Classification using Deep Convolutional Neural Networks</i>	Menggunakan algoritma CNN dengan versi model <i>AlexNet</i> dan <i>VGGNet</i>	Komputer
44	(Pakaya & Suleman, 2018)	Pengelompokan Kualitas Daging Ikan Tuna dengan K-Means Berbasis Histogram Derajat Keabuan	Kualitas daging tuna dengan <i>clustering K-Means</i> berbasis histogram derajat keabuan	Komputer
45	(Dwiyanto et al., 2018)	Alat Pendekripsi Kesegaran Ikan Menggunakan Metode <i>K-Nearest Neighbor</i> Berdasarkan Warna Mata Berbasis ATMega 328	Nilai warna RGB yang didapatkan dari sensor warna, diklasifikasi dengan <i>K-Nearest Neighbors</i> .	Sensor Warna, Komputer

No	Penulis	Judul Penelitian	Metode	Media
46	(Sengar et al., 2017)	<i>Computer Vision Based Technique for Identification of Fish Quality after Pesticide Exposure</i>	Citra mata ikan, penentuan ROI, konversi RGB ke HSV, klasifikasi dengan <i>random forest</i>	Komputer
47	(Misimi et al., 2017)	<i>Application of Matrix-Assisted Laser Desorption/Ionization Mass Spectrometry Imaging for Evaluating the Quality of Fish Fillets</i>	Penentuan kualitas ikan dengan <i>mass spectrometry imaging</i>	Alat <i>mass spectrometry imaging</i> dan computer
48	(Misimi et al., 2017)	<i>Robust Classification Approach for Segmentation of Blood Defects in Cod Fillets Based on Deep Convolutional Neural Networks and Support Vector Machines and Calculation of Gripper Vectors for Robotic Processing</i>	Segmentasi bercak darah pada fillet ikan Codd dengan tekstur seragam menggunakan sistem <i>vision multimodal</i> . Klasifikasi menggunakan <i>Convolutional Neural Networks</i> dan <i>Support Vector Machines</i> untuk klasifikasi ikan fillet yang rusak	Komputer
49	(Asmara et al., 2017)	Identifikasi Kesegaran Daging Sapi Berdasarkan Citranya dengan Ekstraksi Fitur Warna dan Teksturnya Menggunakan Metode <i>Gray Level Co-Occurrence Matrix</i>	Klasifikasi kesegaran daging sapi menggunakan <i>Naïve Bayes</i>	Komputer
50	(Najib et al., 2016)	<i>Fish Quality Study Using Odor Profile Case Based Reasoning (CBR) Classification Technique</i>	Akuisisi data bau dengan <i>electronic nose</i> dan dilatih menggunakan CBR	<i>Electronic nose</i> dan komputer
51	(Cheng et al., 2016)	<i>Developing a Multispectral Imaging for Simultaneous Prediction of Freshness Indicators During Chemical Spoilage of Grass Carp Fish Fillet</i>	<i>Multispektral imaging</i> untuk memprediksi kesegaran ikan selama pembusukan ikan mas	Perangkat multispektral dan komputer

No	Penulis	Judul Penelitian	Metode	Media
52	(Eka Putra, 2016)	Klasifikasi Citra Menggunakan <i>Convolutional Neural Network</i> (Cnn) pada Caltech 101	Klasifikasi citra menggunakan CNN	Komputer
53	(C. A. Lintang et al., 2016)	Rancang Bangun <i>Electronic Nose</i> untuk Mendeteksi Tingkat Kebusukan Ikan Air Tawar	<i>Electronic Nose Sensor</i> untuk mendeteksi tingkat kebusukan ikan air tawar	Sensor <i>electronic nose</i> dan komputer
54	(Arraffi Birahmat ika & M. T. Nasution, 2016)	Rancang Bangun Pencitraan Multispektral Cahaya Tampak untuk Deteksi Kesegaran Ikan Gurami ( <i>Osphronemus Goramy</i> )	Deteksi kesegaran ikan dengan <i>multispektral imaging VIS</i>	Komputer dan perangkat multispektral
55	(Sari & Haryanto, 2016)	Penentuan Kualitas Ikan Bandeng Menggunakan Algoritma <i>Naive Bayes</i> Berdasarkan Tekstur Pada Citra	Metode <i>Naive Bayes</i> sebagai klasifikasi dan tekstur fitur	Komputer
56	(Sari & Haryanto, 2016)	Penentuan Kualitas Ikan Bandeng Menggunakan Algoritma <i>Naive Bayes</i> Berdasarkan Tekstur Pada Citra	Metode <i>Naive Bayes</i> sebagai klasifikasi dan tekstur fitur	Komputer
57	(Cheng et al., 2015)	<i>Development of Hyperspectral Imaging Coupled with Chemometric Analysis to Monitor K Value for Evaluation of Chemical Spoilage in Fish Fillets</i>	<i>Hyperspectral imaging</i> dengan <i>analisis chemometric</i> untuk mengevaluasi kerusakan kimia fillet ikan	Alat <i>hyperspectral imaging</i> dan komputer
58	(Cheng & Sun, 2015)	<i>Data Fusion and Hyperspectral Imaging in Tandem With Least Squares-Support Vector Machine for Prediction of Sensory Quality Index Scores of Fish Fillet</i>	<i>Data fusion</i> dan <i>hyperspectral imaging</i> untuk memprediksi index kualitas sensory fish fillet	Alat <i>hyperspectral</i> dan komputer

No	Penulis	Judul Penelitian	Metode	Media
59	(Astutik, 2015)	Sistem Penentuan Kualitas Ikan Gurame dengan Wavelet, PCA, Histogram HSV dan KNN	Penentuan citra untuk mengenali kualitas induk gurami melalui ekstraksi tekstur kulit sisiknya dengan wavelet haar dan PCA, histogram HSV, klasifikasi menggunakan <i>k-Nearest Neighbors</i> ( <i>k</i> -NN)	Komputer dan kamera digital
60	(F. K. Han et al., 2014)	<i>Quantitative and Qualitative Analysis of Fish Freshness Based on Electronic Tongue Technique</i>	Akuisisi data dengan <i>electronics tongue</i> dengan algoritma <i>K-nearest neighbors</i> (KNN) dan (BP-ANN untuk menilai kesegaran ikan	Komputer
61	(F. Han et al., 2014)	<i>A Nondestructive Method for Fish Freshness Determination with Electronic Tongue Combined with Linear and Non-linear Multivariate Algorithms</i>	Akuisisi data bau dengan <i>electronics tongue</i> , membandingkan metode <i>Fisher LDA</i> dan (SVM)	<i>Electronic nose</i> dan komputer
62	(Shari et al., 2013)	<i>Enhancement of An Infrared Based Fat Measurement Sensor</i>	Pengukuran lemak dengan sensor inframerah yang dipengaruhi oleh kandungan air pada material	Sensor <i>infrared</i> dan komputer
63	(Dowlati et al., 2012)	<i>Application of Machine-Vision Techniques to Fish-Quality Assessment</i>	Penerapan <i>machine vision</i> dan teknologi <i>imaging</i> untuk penentuan kualitas ikan (mengukur dan mengevaluasi ukuran dan volume, memperkirakan berat, mengukur parameter bentuk, menganalisis kulit dan <i>fillet</i> dalam berbagai corak warna, mengenali spesies dan jenis kelamin ikan, dan mendeteksi cacat)	Komputer

No	Penulis	Judul Penelitian	Metode	Media
64	(Jarmin et al., 2012)	<i>A comparison on fish freshness determination method</i>	Menggunakan kuantifikasi indeks warna RGB dan sensor <i>Torrymeter</i> untuk mendeteksi kesegaran ikan	Komputer, sensor
65	(Buniyamin et al., 2011)	<i>Non-Destructive Fish Fat Detection Using Infrared Sensor</i>	Deteksi lemak ikan menggunakan sensor <i>infrared</i>	<i>Infrared sensor, komputer</i>

Penelitian sebelumnya yang meneliti mengenai kualitas ikan telah banyak dilakukan, mulai dari pengukuran kesegaran ikan, dan kualitas ikan. Tabel 2.1 menunjukkan penelitian sebelumnya yang terdiri dari penelitian mengukur kesegaran ikan dan kualitas menggunakan profil bau dari sensor elektronik, profil warna RGB dari sensor warna, spektroskopi, biosensor kimia, sensorik mikrobiologi, kesegaran dan kualitas ikan menggunakan citra mata ikan dengan ANN, CNN, *hyperspectral imaging*, dan algoritma *wavelet* diskrit. Terdapat juga beberapa penelitian untuk mengukur kadar lemak daging, susu atau kualitas jeruk menggunakan metode *near infrared hyperspectral imaging* yang dapat digunakan sebagai referensi dalam penelitian berikutnya. Berdasarkan *review* literatur tersebut, umumnya penelitian tentang penentuan kesegaran ikan dan penelitian penentuan kualitas *grading* tuna loin berdasarkan warna dan tekstur. Dari sisi kebaruan sejauh yang dikenali penulis, belum ada penelitian membangun alat untuk mendeteksi kualitas grade *tuna loin* berdasarkan kesegaran, warna, tekstur dan kandungan lemak daging tuna loin. Dari sisi keaslian penelitian, sejauh yang diketahui penulis ada beberapa aspek keaslian penelitian ini yaitu belum ada alat yang dapat melakukan penentuan kualitas grade daging tuna berdasarkan karakteristik tingkat kesegaran, warna daging, tekstur dan kandungan lemak tuna loin (DiGregorio, 2012)(Gourmets, 2021), walaupun sudah ada penelitian mengenai penentuan kualitas daging tuna, namun penentuan tuna tersebut berdasarkan warna daging dan tekstur daging saja dengan klasifikasi menggunakan algoritma *support vector machine*.

## 2.2 Penentuan Kualitas dan Kesegaran Ikan Tuna

Penentuan kualitas *grade* ikan pada perusahaan pengolahan ikan saat ini dilakukan oleh operator *checker/grader* secara manual dengan melihat ciri fisik dan

warna dari daging ikan dan bau dari ikan. Kualitas mutu ikan tuna dibedakan menjadi tiga kategori utama, yaitu kualitas ekspor, kualitas lokal dan kualitas buruk (*reject*). Kegiatan *grading* dilakukan oleh seorang pemeriksa (*checker/grader*) dengan menusukkan *spike* / alat *coring tube* ke badan ikan untuk mengambil sampel daging ikan. *Spike* berupa alat yang berbentuk batang, tajam dan terbuat dari besi. Pengambilan sampel ikan dengan *spike* dilakukan pada kedua sisi ikan (bagian belakang sirip atau ekor kanan dan kiri) dengan cara menusukan *coring tube* ke tubuh ikan, sehingga didapatkan potongan daging ikan tuna. Kesalahan dalam pengecekan daging tuna akan meninggalkan bekas dari proses *checker*, dan hal ini akan mempengaruhi harga jual daging ikan tuna.

Kualitas *grade* ikan dapat menurun karena adanya aksi enzimatis dan aksi bakteri akibat penanganan ikan yang kurang pada saat pendaratan kapal sampai pada aktifitas pengiriman ke perusahaan pengolahan ikan (dipengaruhi oleh suhu ikan, *cross contamination* dan lain-lain)(Sidik et al., 2013). Kedua aksi ini menguraikan komponen penyusun jaringan tubuh ikan sehingga menghasilkan perubahan fisik seperti daging ikan menjadi lunak dan perubahan kimia yang menghasilkan senyawa yang mudah menguap dan berbau busuk(Sidik et al., 2013). Penentuan kualitas *grade* tuna tergantung dari warna daging, kondisi mata, warna kulit, tekstur daging dan kondisi penampakan ikan. Ikan tuna yang memiliki kualitas bagus adalah yang memiliki kondisi daging yang kenyal, banyak minyak, warna daging cerah, tidak ada kerusakan pada daging seperti adanya sashi atau bolong dan tidak terlihat adanya gradasi warna pelangi pada daging(Sidik et al., 2013). Sedangkan tuna yang memiliki kualitas yang buruk memiliki kondisi daging yang lembek/pucat, tidak ada minyak, warna daging merah buram/gelap, ada sashi/bolong dan adanya gradasi warna pelangi pada daging(Sidik et al., 2013). Ikan tuna yang memiliki kualitas paling baik, biasanya akan langsung di ekspor dalam bentuk utuh dan segar/*fresh* (tidak dibekukan terlebih dahulu), sedangkan ikan dengan kualitas mutu sedang memerlukan *treatment* terlebih dahulu sebelum diekspor(Sidik et al., 2013). Produk olahan tuna kualitas sedang berupa produk utuh beku dalam bentuk utuh (*frozen whole gilled and gutted*), produk loin (*frozen loin*), steak (*frozen steak*), tuna saku dan produk tuna kaleng (*canned tuna*). Sedangkan ikan dengan *grade* lokal dan *grade reject* akan dijual di pasar domestik lokal untuk dijual di pasar lokal atau diolah menjadi produk olahan

domestik(Sidik et al., 2013). Kesegaran ikan ditentukan dari warna kulit terang dan jernih, mata tampak terang, jernih, menonjol dan cembung, insang berwarna merah sampai merah tua dan dagingnya kenyal (Pusdik.kkp.go.id, 2019).

Penelitian dari (Sidik et al., 2013), mengidentifikasi sumber suplai tuna di PPS Nizam Zachman Jakarta, terkait dengan harga, mutu, jumlah dan daerah asalnya, dan sistem perdagangan komoditi tuna di PPS Nizam Zachman Jakarta. Metode penelitian yang digunakan adalah metode survei, dan data yang dikumpulkan melalui pengumpulan *tally sheet* hasil pembongkaran kapal tuna *longline* dengan teknik sampling dan observasi terhadap proses pembongkaran tuna *longline* di pelabuhan. Pelabuhan perikanan yang biasanya mengirimkan tuna ke PPSNJZ adalah PPS Benoa Bali, PPN Palabuhan Ratu, dan PPS Cilacap. Mutu tuna segar yang di ekspor memiliki grade AAA, AAF, AF, AA, A+ dan A, sedangkan tuna lokal memiliki grade B+, B, B-, *Reject/C*, Oba/D. Berdasarkan uji statistik, hubungan jumlah dan mutu terhadap harga dapat dikatakan sangat kuat dengan pengaruh sebesar 73,8%, pengaruh jumlah dan mutu sangat signifikan terhadap harga.

Tabel 2.2 Kriteria *Grading* Produk Tuna Loin(Sidik et al., 2013)

No	Grade	Ciri Daging	Ciri Minyak	Ciri Warna	Ciri Tekstur Permukaan	Warna Pelangi
1	AAA	Kenyal	Banyak minyak	Merah terang cerah segar	Tidak ada berlubang	Tidak ada
2	AAF	Kenyal	Banyak minyak	Merah terang, agak cerah, segar	Tidak ada berlubang	Tidak ada
3	AF	Kenyal	Minyak lumayan banyak	Merah terang sangat segar	Tidak ada berlubang	Tidak ada
4	AA	Kenyal	Minyak sedikit	Merah terang	Tidak ada berlubang	Tidak ada
5	A+	Kenyal	Minyak sedikit	Merah	Tidak ada berlubang	Tidak ada
6	A	Kenyal	Minyak lebih sedikit dari A+	Merah	Tidak ada berlubang	Tidak ada
7	A-	Kenyal	Minyak sedikit	Merah/terang	Tidak ada	Tidak ada

No	Grade	Ciri Daging	Ciri Minyak	Ciri Warna	Ciri Tekstur Permukaan	Warna Pelangi
8	B+	Kenyal	Tidak ada minyak/lemak	Merah sedikit redup	Tidak ada	Pelangi tipis
9	B	Kenyal	Sedikit minyak	Merah agak pucat	Tidak ada	Pelangi sedikit tebal
10	B-	Sedikit kenyal	Tidak ada minyak/kondisi jelek	Putih	Tidak ada	Pelangi tebal
11	R	Lembek	Tidak ada minyak /sudah putih	Merah gelap	Tidak ada	Pelangi tebal
12	R	Kasar, lembek	Tidak ada minyak, pucat	Merah gelap	Ada sashi, lubang dipermukaan	Pelangi tebal

Menurut *Luxe Gourmet* (Gourmets, 2021), penentuan kualitas *grade* dilakukan dengan mengamati kondisi kesegaran(*freshness*) dari penampilan fisik ikan. Salah satu tanda kesegaran yang paling jelas dari penampakan kerahnya saat kepala telah dilepas. Kemudian kulit, sisik, dan sirip ikan diperiksa secara visual. Setelah bagian luar di evaluasi, maka petugas inspektor melihat ke bagian dalam misalnya ke bagian daging dan dinding perut. Kriteria penentuan kualitas *grade* produk tuna loin menurut *Luxe Gourmet* ditunjukkan pada Tabel 2.3.

Tabel 2.3. Kriteria Grading Produk Tuna Loin Menurut Luxe Gourmet (Gourmets, 2021)

No	Grade	Komponen	Karakteristik
1	#1	Warna Daging	Tuna <i>grade</i> harus memiliki warna merah cerah, mengkilat. Garis darah dari sampel harus berwarna merah lebih gelap dari daging, seharusnya tidak hitam atau coklat
	#1	Tekstur	Tuna <i>grade</i> harus memiliki tekstur yang halus, tidak kasar atau berbutir, tekstur permukaan mengandung lemak/minyak
2	#2+	Warna Daging	Warna merah agak cerah dan mendekati tuna <i>grade</i> #1, warna merah agak cerah kurang konsisten
	#2+	Tekstur	Memiliki lebih sedikit lemak/minyak. Daging masih terasa basah dan halus seperti di <i>grade</i> #1. Memiliki rasa yang baik dan solid untuk disentuh

No	Grade	Komponen	Karakteristik
	#2	Warna Daging	Warnanya merah pudar
3	#3	Warna Daging	Warnanya agak coklat

Menurut *Seafood Handling Guidelines*, karakteristik penentuan *grade* ikan tuna dapat dilihat pada Tabel 2.4.

Tabel 2.4. Kriteria Penentuan *Grade* Produk Tuna Loin Menurut *Sydney Fish Market* (*Sydney Fish Market Pty Ltd, 2015*)

No	Kategori	<i>Grade</i>				
		A+ (1)	A (2)	B (3)	C (4)	R (5)
1	Bau	Berbau segar	Berbau segar	Berbau segar	Bau yang tidak menyenangkan /kurang nyaman	
2	Warna Kulit	Kulit/sisik cerah dan tidak rusak.	Kulit/sisik cerah dan tidak rusak	Kerusakan kecil pada kulit. Kulit mungkin pucat	Kulit/sisik pucat atau terdapat kerusakan kulit yang mayor /dominan	
3	Insang	Warna merah terang	Warna merah terang	Warna merah pucat/merah muda. Insang sedikit bau tapi tidak menjijikkan	Insang berwarna kusam dan berbau menjijikkan	
4	Isi perut	Kuat elastis saat disentuh	Kuat elastis saat disentuh	Sedikit lembek saat disentuh	Lembek saat disentuh	
5	Daging loin	Kuat elastis saat disentuh	Elastis saat disentuh	Agak lembek jika disentuh	Lembek jika disentuh	

Menurut Robert DiGregorio dalam bukunya *Tuna Grading and Evaluation* (DiGregorio, 2012) menyatakan terdapat 5 ciri dalam grading ikan tuna yaitu *freshness*

(kesegaran), ukuran dan bentuk ikan, warna daging, tekstur, lapisan lemak pada daging ikan. Salah satu cara untuk menilai mutu ikan yaitu berdasarkan mekanisme *organoleptic* dengan cara *sensory assessment*. *Sensory* merupakan cara menilai mutu ikan menggunakan indera manusia untuk mengukur karakteristik dan penerimaan kualitas produk pangan dalam pengendalian kualitas dan pengembangan produk pangan(Nasional, 2006)

Tabel 2.5. Kriteria Grading Tuna Menurut Robert DiGregorio (DiGregorio, 2012)

No	Kriteria	Kualitas <i>Grade</i> Ikan Tuna			
		#1	#2+	#2	#3
1	<i>Freshness/</i> kesegaran	Kerah, atau tengkuk, yang kepalanya telah di lepas, tampak bersih tanpa perubahan warna. Bau <i>seafood</i> segar, rumput laut dan bau seperti kerang.	Tuna <i>grade</i> #2+ mendekati warna kulit tuna #1. Kerah dan perut tuna <i>grade</i> #2+ mungkin sedikit lebih rata atau tidak seterang #1	Bau daging seperti susu, bawang putih atau pedas, roti, agak tengik, sedikit asam.	Penampilan luarnya agak rusak. Perubahan warna perut kehijauan atau kekuningan. Daging ikan terdapat lecet. Sirip mungkin rusak. Bau ikan agak asam, dan tengik.
2	Bentuk/ ukuran ikan	Minimal berukuran 60 pon (27.2 Kg) atau lebih besar. Ikan ukuran besar memiliki <i>yield</i> yang lebih baik dan ukuran loin yang lebih diinginkan. Bentuknya bulat, harus penuh dengan <i>belly</i> yang tebal.	Ukuran dan bentuk ikan tuna #2+ mirip dengan ikan #1. Ikan #2+ mungkin lebih kecil, bahkan dalam 40-60 kisaran pon (27 Kg). Bentuknya mungkin lebih panjang dan lebih kurus dibanding #1.	Ukuran dan bentuk ikan tuna #2 mirip dengan #2	<i>Grade</i> #3 tidak ada ciri khas pada bentuk dan ukuran ikan (semua ukuran dan bentuk masuk ke dalam <i>grade</i> #3)

No	Kriteria	Grade Ikan Tuna			
		#1	#2+	#2	#3
3	Warna daging tuna	Warna daging tuna cerah merah, mengkilat dan tembus pandang seperti merah lampu <i>traffic light</i>	Potongan ekor berwarna merah dan mungkin sedikit berubah warna di dekat kulit. Sampel inti harus berwarna merah dengan warna merah tidak secerah dari grade #1. Daging loin berwarna merah agak terang dan mungkin sedikit lebih gelap atau bahkan sedikit lebih terang dan warna merahnya sedikit lebih pudar dari warna grade #1	Warna <i>grade #2</i> tidak akan menunjukkan kecerahan yang sama dengan #2+ atau #1. Warna agak gelap dan mungkin hitam. Warna merah pinggang dan <i>grade #2</i> tidak sekonsisten loin dan <i>steak</i> dari nilai yang lebih tinggi. Warna merah <i>grade #2</i> lebih pudar dan seperti warna merah bata sampai warna magenta. Loin mungkin kondisinya kurang sempurna seperti memar dan memiliki warna yang tidak rata.	Warna daging tuna hampir selalu coklat tua bahkan hitam kecoklatan dan terkadang terlihat warna krem pucat kusam dan suram. Sampel inti biasanya menunjukkan satu warna coklat tua atau gelap.
4	Kandungan minyak/ <i>Fat</i>	Kandungan minyak/lemak yang tinggi. Tuna dengan dinding perut yang tebal kemungkinan besar akan menjadi ikan berlemak.	Kandungan minyak/lemak sedikit. Lemak tidak terlihat jelas pada sampel inti atau ekor.	Tidak ada lemak pada daging tuna.	Tidak ditemukan lemak/ <i>fat</i> pada daging tuna.

No	Kriteria	Grade Ikan Tuna			
		#1	#2+	#2	#3
5	Tekstur Daging Tuna	Tekstur daging yang halus. Daging ekornya halus, tidak kasar, atau kering. Kandungan minyak/lemak yang jelas harus mudah dirasakan saat menggosok sampel antara ibu jari dan jari telunjuk. Permukaan daging terasa lengket saat disentuh.	Ikan #2+ memiliki lebih sedikit lemak/minyak, teksturnya daging akan terasa lebih padat kompak dan elastis. Seharusnya masih terasa basah dan halus seperti #1, tetapi dengan sedikit lemak. Permukaan daging ikan tidak akan terasa lengket. <i>Grade #2+ loin memiliki tekstur permukaan yang baik dan solid.</i>	Daging tuna #2 terasa lebih kecil dan agak kering karena tidak adanya lemak yang menimbulkan lengket. Dagingnya tidak akan sebasah dan sehalus #1 dan #2+ dan biasanya akan terasa lebih kering dan kasar	Tekstur daging tidak ada lemak pada daging tuna, biasanya kasar dan kering.

Berdasarkan salah satu kriteria penentuan grading tuna menurut Robert DiGregorio, yaitu kesegaran, maka untuk kriteria kesegaran ikan tuna yang lebih lengkap ditunjukkan pada Tabel 2.6.

Tabel 2.6. Kriteria Ikan Segar (SNI, 2013) (SANTHI, 2017)

No	Kondisi Segar	Kondisi Tidak Segar
1	Penampilan ikan diamati dari bola mata cembung, kornea dan pupil jernih mengkilap. Warna insang merah tua atau coklat kemerahan, kurang cemerlang dengan sedikit lapisan lendir transparan, jernih, mengkilap cerah.	Penampilan diamati dari bola mata cekung, kornea keruh, pupil keabu-abuan, tidak mengkilap. Warna insang abu-abu atau coklat keabu-abuan dengan lendir putih susu/coklat bergumpal. Lendir tebal sedikit menggumpal, berubah warna, warnanya kusam
2	Sayatan daging tampak cemerlang spesifik jenis, jaringan daging kuat	Sayatan daging tampak kusam, jaringan daging kurang kuat
3	Berbau segar, seperti rumput laut dan sejenisnya	Mulai berbau asam seperti susu asam, berbau amoniak ( <i>trimetilamin</i> ) atau berbau busuk ( <i>hydrogen sulfida</i> )

No	Kondisi Segar	Kondisi Tidak Segar
4	Tekstur padat, kompak, elastis, bila daging ditekan dengan jari tidak tampak bekas lekukan	Tekstur lunak bekas jari terlihat dan sangat lambat hilang/tampak bekas lekukan

### 2.3 Jenis Sensor Gas

Terdapat berbagai jenis sensor yang dapat digunakan untuk mendeteksi gas atau bau. Jenis sensor gas tersebut disajikan pada Tabel 2.7.

Tabel 2.7. Jenis Sensor Gas dan Kegunaannya (ShowRange, n.d.),  
(Davidegironi, 2018)

No	Sensor	Deskripsi
1	MQ-2	Sensor gas yang sensitif terhadap bau gas metana, butan, LPG, dan asap rokok. Sensor ini digunakan untuk mendeteksi kebocoran LPG, asap rokok.
2	MQ-3	Sensor gas yang sensitif dengan bau gas alkohol, etanol, dan asap rokok. Sensor MQ-3 lebih sering digunakan untuk mengetahui adanya gas alkohol atau tidak
3	MQ-4	Sensor gas yang sensitif terhadap bau gas metana dan CNG. Gas metana adalah gas yang mudah meledak. MQ-4 dapat dipilih untuk mendeteksi kandungan gas metana di udara
4	MQ-5	Sensor untuk deteksi kebocoran gas pada rumah dan industri, sangat baik untuk mendeteksi gas LPG, gas alam, alkohol, dan asap rokok
5	MQ-6	Sensor gas yang sensitif terhadap bau gas LPG dan butana. Sensor ini hampir sama dengan sensor MQ-2, dapat mendeteksi gas LPG dan gas butan
6	MQ-7	Sensor gas yang sensitif terhadap karbon monoksida, dan digunakan untuk mengetahui kadar CO di udara
7	MQ-8	Sensor gas yang sensitif terhadap gas hidrogen. Sensor ini biasa digunakan untuk mendeteksi kandungan hidrogen di udara untuk mencegah adanya kebakaran.
8	MQ-9	Sensor gas untuk mendeteksi gas dengan siklus suhu tinggi dan rendah. Saat suhu rendah dapat mendeteksi CO (dipanaskan oleh 1.5V). Saat suhu tinggi (dipanaskan dari tegangan 5.0V), sensor dapat mendeteksi gas metana, propana dan gas lain yang mudah terbakar.
9	MQ-135	Sensor gas yang sensitif terhadap <i>ammonia</i> , <i>benzena</i> , alkohol, dan asap rokok. Sensor ini biasanya digunakan untuk mengetahui adanya alkohol dan asap rokok.

No	Sensor	Deskripsi
10	MQ-136	Sensor gas yang sensitif terhadap gas hidrogen dan <i>sulfide</i>
11	MQ-137	Sensor gas yang sensitif terhadap gas <i>ammonia</i> , yang dapat memonitor asam organic <i>trimethylamine</i> , <i>cholamine</i> .
12	MQ-138	Sensor gas yang sensitif terhadap gas <i>benzena</i> , <i>toluene</i> , alkohol, <i>propane</i> , <i>formaldehida</i> , dan <i>hydrogen</i>

## 2.4 Spesifikasi Teknis Sensor

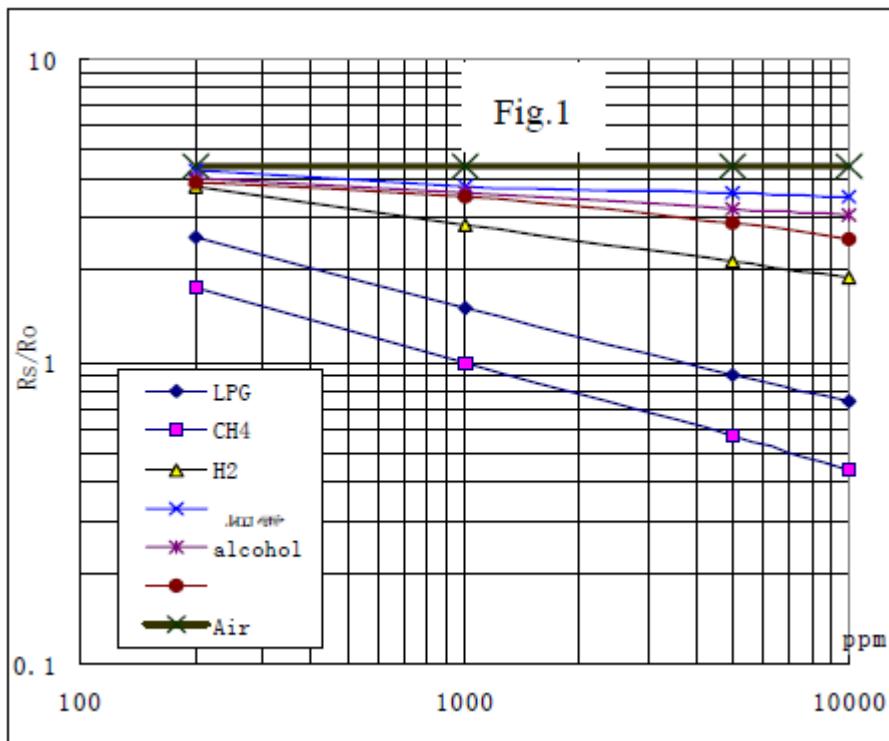
### 2.4.1 Sensor Gas MQ-4

MQ-4 adalah sensor untuk mendeteksi kadar gas alam terkompresi / CNG (*compressed natural gas*). Sensor MQ-4 mendeteksi gas metana dalam udara yang dirangkaikan dengan mikrokontroler Arduino. Program yang dibuat dapat di *upload* ke mikrokontroler untuk menentukan aksi berdasarkan data yang terbaca, misalnya menyalaikan alarm saat kadar gas metana ini mencapai ambang batas tertentu yang membahayakan, atau menampilkan kadar ppm gas (*parts per million*).



Gambar 2.2 Sensor MQ-4(ShowRange, n.d.)

Sensor MQ-4 seperti ditunjukkan pada Gambar 2.2 merupakan sensor yang sangat sensitif terhadap CNG dan dapat mendeteksi konsentrasi gas di udara mulai dari 200 ppm hingga 10.000 ppm. Keluaran sensor ini berupa resistansi analog yang dengan mudah dapat dikonversi menjadi tegangan dengan menambahkan satu resistor. Hasil pembacaan sensor dapat dibaca oleh pin ADC (*analog to digital converter*) pada mikrokontroler.



Gambar 2.3. Karakteristik Sensitivitas Sensor MQ-4 (ShowRange, n.d.)

Gambar 2.3 menunjukkan karakteristik sensitivitas sensor MQ-4 pada konsentrasi gas LPG, CH<sub>4</sub>, H<sub>2</sub>, alkohol dan udara. Sumbu vertikal (Y) menyatakan rasio resistansi karakteristik sensor (Rs/Ro), sedangkan sumbu horizontal (X) menunjukkan konsentrasi gas yang diukur dalam satuan ppm. Rs berarti resistansi sensor pada jenis gas yang berbeda, dan Ro berarti resistansi dalam 1000 ppm gas metana pada temperatur dan kelembaban tertentu. Adapun spesifikasi teknis sensor MQ-4 ditunjukkan pada Tabel 2.8.

Tabel 2.8. Spesifikasi Teknis Sensor MQ-4 (ShowRange, n.d.)

No	Kategori	Deskripsi
1	Jenis sensor	Semikonduktor
2	Deteksi gas	Gas alam / methane
3	Konsenstrasi gas	300 – 10,000 ppm
4	Circuit Loop Voltage ( $V_C$ )	$\leq 24$ V DC
5	Circuit Heater Voltage ( $V_H$ )	$5$ V $\pm 0.2$ V AC atau DC
6	Circuit Load Resistance ( $R_L$ )	Adjustable
7	Heater Resistance ( $R_H$ )	$31 \Omega \pm 3 \Omega$ (temperatur ruangan)

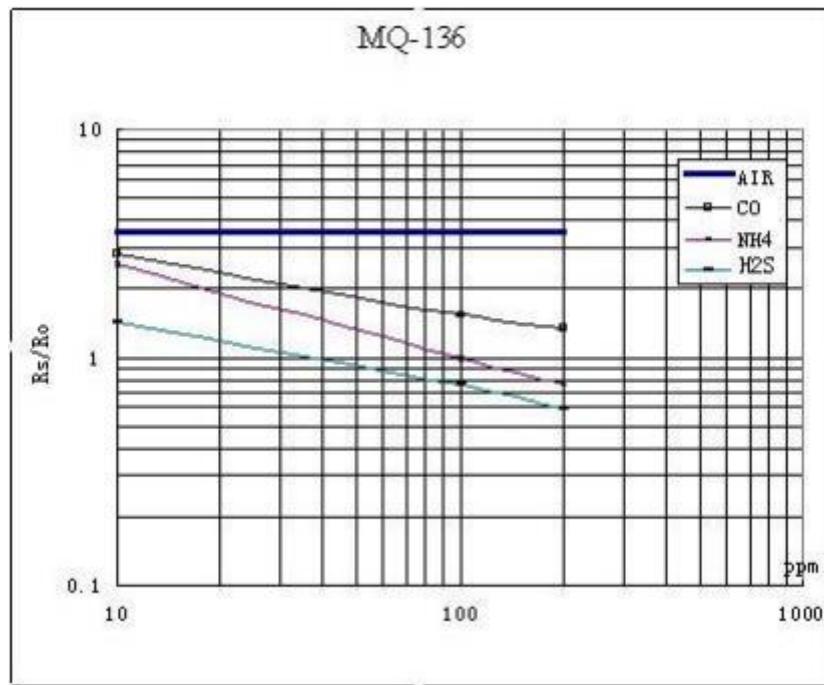
No	Kategori	Deskripsi
8	<i>Heater Consumption (P<sub>H</sub>)</i>	$\leq 900 \text{ mW}$
9	<i>Sensing Resistance (Rs)</i>	$2\text{K}\Omega - 20\text{ K}\Omega$ ( 5000 ppm CH <sub>4</sub> )
10	<i>Sensitivity (S)</i>	$\text{Rs(dи udara) / Rs(5000ppm CH4)} \geq 5$
11	Temperatur Kelembaban	$20^{\circ}\text{C} \pm 2^{\circ}\text{C}$ dan $65\% \pm 5\% \text{ RH}$
12	Standar tegangan pengujian	V <sub>c</sub> $5.0\text{V} \pm 0.1\text{V}$ dan V <sub>H</sub> $5.0\text{V} \pm 0.1\text{V}$
13	Waktu pemanasan ( <i>preheat</i> )	di atas 48 jam
14	Waktu <i>response</i>	$\leq 10$ detik
15	Waktu pemulihan	$\leq 30$ detik

#### 2.4.2 Sensor Gas MQ-136

Sensor MQ-136 sangat peka terhadap gas yang mengandung hidrogen sulfida (H<sub>2</sub>S). Hidrogen sulfida juga dikenal dengan nama sulfur hidrida, gas asam dan gas limbah (*sewer gas*). Gas ini juga muncul pada gas yang timbul dari aktivitas gunung berapi dan gas alam. Struktur dan konfigurasi sensor gas MQ-136 terbuat dari tabung keramik mikro AL<sub>2</sub>O<sub>3</sub>, lapisan sensitif Tin Dioxide (SnO<sub>2</sub>), elektroda pengukur dan pemanas dipasang ke dalam kerak terbuat dari plastik dan jaring *stainless steel*. MQ-136 memiliki 6 pin, 4 di antaranya digunakan untuk mengambil sinyal, dan 2 lainnya digunakan untuk menyediakan arus pemanas (*heater*) yang digunakan untuk membersihkan ruangan sensor dari kontaminasi udara luar agar sensor dapat bekerja kembali secara efektif (Amazon.co.uk, 1996). Sensor MQ-136 ditunjukkan pada Gambar 2.4.



Gambar 2.4 Sensor MQ-136 (ShowRange, n.d.)



Gambar 2.5 Karakteristik Sensitivitas Sensor MQ-136 (ShowRange, n.d.)

Gambar 2.5 menunjukkan karakteristik sensitivitas sensor MQ-136 pada konsentrasi gas H<sub>2</sub>S, NH<sub>4</sub>, CO, dan udara bebas. Sumbu vertikal (Y) menyatakan rasio resistansi karakteristik sensor ( $R_s/R_o$ ), sedangkan sumbu horizontal (X) menunjukkan konsentrasi gas yang diukur dalam satuan ppm.  $R_s$  berarti resistansi sensor pada jenis gas yang berbeda, dan  $R_o$  berarti resistansi dalam 1000 ppm gas pada temperatur dan kelembaban tertentu. Adapun spesifikasi teknis sensor MQ-136 ditunjukkan pada Tabel 2.9.

Tabel 2.9. Spesifikasi Teknis Sensor MQ-136 (ShowRange, n.d.)

No	Kategori	Deskripsi
1	Jenis sensor	Semikonduktor
2	Deteksi gas	Asam sulfat
3	Konsentrasi gas	300 – 10,000 ppm
4	<i>Circuit Loop Voltage (V<sub>C</sub>)</i>	5 V ± 0.1 V AC atau DC
5	<i>Circuit Heater Voltage (V<sub>H</sub>)</i>	5 V ± 0.1V AC atau DC
6	<i>Circuit Load Resistance (R<sub>L</sub>)</i>	dapat di atur ( <i>adjustable</i> )
7	<i>Heater Resistance (R<sub>H</sub>)</i>	31 Ω ± 5% (temperatur ruangan)

No	Kategori	Deskripsi
8	<i>Heater Consumption (<math>P_H</math>)</i>	$\leq 800 \text{ mW}$
9	<i>Sensing Resistance (<math>R_s</math>)</i>	$30 \text{ K}\Omega\text{-}200 \text{ K}\Omega$ (10ppm H <sub>2</sub> S)
10	Temperatur Kelembaban	$20^\circ\text{C}\pm2^\circ\text{C}$ dan $65\%\pm5\%$ R <sub>H</sub>
11	Standar Tegangan Pengujian	V <sub>c</sub> $5.0\text{V}\pm0.1\text{V}$ dan V <sub>H</sub> $5.0\text{V}\pm0.1\text{V}$
12	Waktu pemanasan ( <i>preheat</i> )	di atas 24 jam
13	Waktu respons	$\leq 1$ detik
14	Waktu pemulihan	$\leq 30$ detik

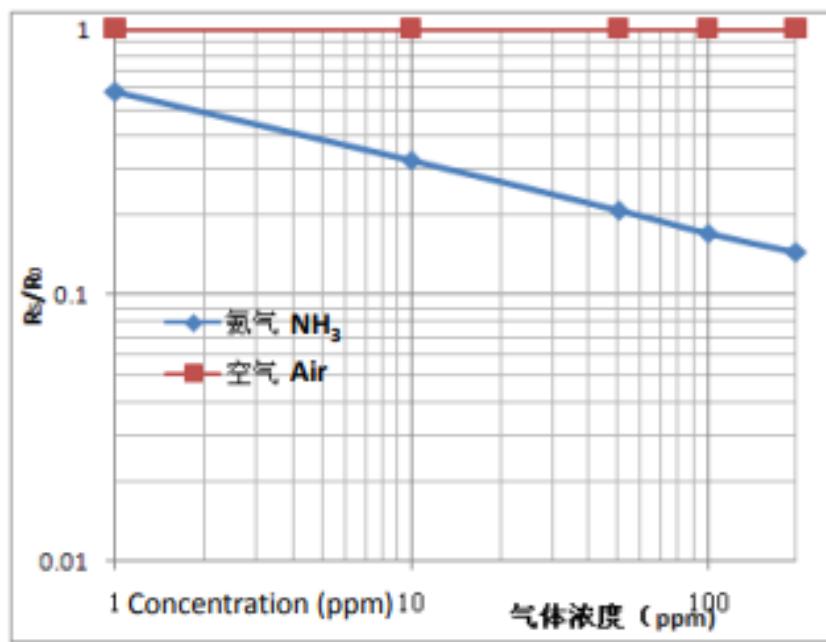
#### 2.4.3 Sensor Gas MQ-137

Sensor MQ-137 umumnya digunakan untuk mendeteksi gas NH<sub>3</sub> di udara, alarm kebocoran gas NH<sub>3</sub> industri. Bahan sensitif sensor gas MQ137 adalah SnO<sub>2</sub>, yang dengan konduktivitas lebih rendah di udara bersih. Saat terdapat gas NH<sub>3</sub>, konduktivitas sensor semakin tinggi dengan meningkatnya konsentrasi gas. Sensor gas MQ137 memiliki sensitivitas tinggi terhadap gas NH<sub>3</sub> dan gas trimetilamina, kolamin dengan baik dan merupakan jenis biaya rendah.



Gambar 2.6 Sensor MQ-137 (ShowRange, n.d.)

Gambar 2.7 menunjukkan karakteristik sensitivitas sensor MQ-137. Sumbu vertikal menunjukkan rasio resistansi sensor (R<sub>s</sub>/R<sub>0</sub>), sedangkan sumbu horizontal (X) menunjukkan konsentrasi gas dalam ppm. R<sub>s</sub> menunjukkan resistansi gas target dengan konsentrasi berbeda, R<sub>0</sub> menunjukkan resistansi sensor pada udara segar.



Gambar 2.7 Karakteristik Sensitivitas Sensor MQ-137 (ShowRange, n.d.)

Adapun spesifikasi teknis dari sensor MQ-137 ditunjukkan pada Tabel 2.10.

Tabel 2.10. Spesifikasi Teknis Sensor MQ-137 (ShowRange, n.d.)

No	Kategori	Deskripsi
1	Jenis sensor	Semikonduktor
2	Deteksi gas	Gas amoniak (NH <sub>3</sub> )
3	Konsentrasi gas	5 ~ 500 ppm NH <sub>3</sub>
4	<i>Circuit Loop Voltage (V<sub>C</sub>)</i>	$\leq 24\text{V DC}$
5	<i>Circuit Heater Voltage (V<sub>H</sub>)</i>	$5\text{ V} \pm 0.1\text{V AC atau DC}$
6	<i>Circuit Load Resistance (R<sub>L</sub>)</i>	dapat di atur ( <i>adjustable</i> )
7	<i>Heater Resistance (R<sub>H</sub>)</i>	$29\Omega \pm 3\Omega$ (suhu ruangan)
8	<i>Heater Consumption (P<sub>H</sub>)</i>	$\leq 900\text{ mW}$
9	<i>Sensing Resistance (R<sub>s</sub>)</i>	30 K $\Omega$ -200 K $\Omega$ (10 ppm H <sub>2</sub> S)
10	Temperatur Kelembaban	$20^\circ\text{C} \pm 2^\circ\text{C}$ dan $55\% \pm 5\% R_H$
11	Standar Tegangan Pengujian	V <sub>C</sub> 5.0V $\pm 0.1\text{V}$ dan V <sub>H</sub> 5.0V $\pm 0.1\text{V}$
12	Waktu pemanasan ( <i>preheat</i> )	di atas 48 jam
13	Waktu respons	$\leq 1$ detik
14	Waktu pemulihan	$\leq 30$ detik

## 2.5 Perangkat Pengukuran Kadar Gas

Penelitian ini menggunakan instrumen pengukuran ppm (kandungan gas) dari bau ikan, untuk memverifikasi hasil pengukuran dari sensor gas. Kalibrasi sensor gas dilakukan berdasarkan grafik sensitifitas dari masing-masing sensor gas (Gambar 2.3, Gambar 2.5 dan Gambar 2.7), sehingga sensor gas menampilkan nilai kadar gas dalam satuan ppm saat mendeteksi bau dari ikan. Nilai ppm dari sensor gas tersebut diverifikasi dengan membandingkan dengan nilai ppm hasil pengukuran instrumen gas amonia ( $\text{CH}_3$ ), asam sulfat ( $\text{H}_2\text{S}$ ), dan gas *methana* ( $\text{NH}_3$ ).

### 2.5.1 Instrumen Pengukuran Gas *Methana* ( $\text{CH}_4$ )

Pengukuran gas methana ( $\text{CH}_4$ ) menggunakan instrumen MESTEK CDGA02A. Instrumen ini untuk mendeteksi kebocoran gas dan menganalisis gas yang mudah terbakar misalnya  $\text{CH}_4$ , *ethanol*, *propane*, *benzena*, *hexane*, *buthane*, dan lainnya. MESTEK CDGA02A ditunjukkan pada Gambar 2.8



Gambar 2.8. MESTEK CDGA02A (Mestek, n.d.)

Spesifikasi teknis MESTEK CDGA02A pada Tabel 2.11.

Tabel 2.11. Spesifikasi Teknis Mestek CDGA02A (Mestek, n.d.)

No	Kategori	Deskripsi
1	Jenis gas yang dideteksi	<i>natural gas</i> , <i>coal gas</i> dan <i>petroleum gas</i>
2	Deteksi aliran	1L / menit
3	Resolusi gas	1% LEL / 1 PPM
4	Resolusi temperatur	0.1°C
5	Range pengukuran gas	0-100% LEL / 0 – 50000 ppm ( <i>automatic</i> )

No	Kategori	Deskripsi
6	Range pengukuran temperatur	0 – 50°C
7	Sumber daya	1.5 V x 3 AAA
8	Akurasi pengukuran	± 5% FS
9	Metode sampling	<i>Diffusion</i>
10	Kecepatan respons	2 detik
11	Metode alarm	<i>Sound, display layar</i>
12	Waktu <i>warm up</i>	30 detik
13	Waktu respons	< 30 detik

### 2.5.2 Instrumen Pengukuran Gas Hidrogen Sulfida (H<sub>2</sub>S)

Pengukuran gas hidrogen sulfida (H<sub>2</sub>S) menggunakan instrumen *Wintact* WT8822. Instrumen ini untuk mendeteksi konsentrasi gas hidrogen sulfida (H<sub>2</sub>S) dengan konsentrasi 0 – 100 ppm. Perangkat *Wintact* WT8822 ditunjukkan pada Gambar 2.9.



Gambar 2.9. *Wintact* WT8822 (DZY Instrument, n.d.)

Spesifikasi teknis *Wintact* WT8822 ditunjukkan pada Tabel 2.12.

Tabel 2.12. Spesifikasi Teknis *Wintact* WT8822 (DZY Instrument, n.d.)

No	Kategori	Deskripsi
1	Deteksi gas	Hidrogen Sulfida
2	Range pengukuran	0 – 100 ppm
3	Overload maksimum	500 ppm

No	Kategori	Deskripsi
4	Waktu response	< 30 detik
5	Jenis sensor	<i>Electrochemical</i> sensor H <sub>2</sub> S
6	Sumber daya	1.5 V x 3 AAA

### 2.5.3 Instrumen Pengukuran Gas Amonia (NH<sub>3</sub>)

Pengukuran gas amonia (NH<sub>3</sub>) menggunakan alat test *Hydrion AM-40, Ammonia Test Paper* (Laboratory, 2020). Kertas uji *hydrion ammonia meter* dirancang dan dikalibrasi untuk mengukur jumlah amonia di udara dalam satuan ppm untuk mendeteksi kandungan amonia. Bagan warna memiliki deteksi kandungan amonia berkisar antara 0 ppm, 5 ppm, 10 ppm, 20 ppm, 50 ppm dan 100 ppm. Kertas uji dengan bagan warna yang sudah dikalibrasi khusus dan kotak *polipropilena*. Pengujian dengan menggunakan selembar kertas uji yang dibasahi dengan air dan dipaparkan ke udara, dan menunggu 15 detik dan membandingkan strip uji dengan bagan warna yang dikalibrasi menunjukkan kadar ppm amonia di udara seperti pada Gambar 2.10.



Gambar 2.10. *Hydrion AM-40, Ammonia Test Paper* (Laboratory, 2020)

Spesifikasi teknis instrument pengukuran amonia hydrion AM-40 ditunjukkan pada Tabel 2.13.

Tabel 2.13. Spesifikasi Teknis *Hydrion AM-40, Ammonia Test Paper* (Laboratory, 2020)

Model	<i>ammonia test paper</i>
Waktu respons	15 detik
Rentang pengukuran	0 , 5, 10, 20, 50, 100 ppm
Kapasitas pengujian	750 - 1000 pengujian

## 2.6 Pemilihan Sensor Deteksi Kesegaran Ikan

Menurut Airlangga (2019), indikator untuk mengukur tingkat kesegaran ikan dan sebagai batasan yang layak dikonsumsi dapat dilakukan dengan pengujian TVB (*Total Volatile Base*) (Airlangga, 2019). *Total Volatile Base* (TVB) atau basa yang mudah menguap, terbentuk dalam otot jaringan ikan yang sebagian besar terdiri atas amonia, *trimethylamine* (TMA) dan *dimethylamine* (DMA) dengan kadar berbeda tergantung jenis ikan (Nurhayati et al., 2019) (Patty et al., 2015). Semakin rendah mutu ikan, maka kadar TVB semakin meningkat (Nurhayati et al., 2019) (Patty et al., 2015). Kenaikan kadar TVB terutama disebabkan oleh peningkatan jumlah bakteri sebagai parameter pembusukan ikan (S.Made, 2018) (Kaiang et al., 2016) (Nurhayati et al., 2019) (Patty et al., 2015). Kenaikan kadar TVB disebabkan oleh peningkatan jumlah bakteri yang menyebabkan turunnya kualitas ikan (Nurhayati et al., 2019) (Patty et al., 2015). TVB merupakan hasil dekomposisi protein oleh aktivitas bakteri dan enzim, dimana hasil pemecahan protein menimbulkan bau busuk seperti amonia, H<sub>2</sub>S, merkaptan, phenol, kresol, indol dan skatol. Ikan dinyatakan busuk ketika kadar TVB nya melebihi 30 mg-N/100 gram (Nurhayati et al., 2019) (Patty et al., 2015).

Penelitian ini menggunakan sensor gas jenis MQ sebagai akuisisi bau berdasarkan pertimbangan biaya, sensor MQ harganya relatif murah (*low cost sensor*). Sensor MQ memiliki sensitivitas yang baik terhadap gas dengan jangkauan yang cukup luas dan sensitivitas yang tinggi terhadap gas alam, usia pakai yang cukup panjang (Indahwati & Nurhayati, 2012). Sensor MQ menggunakan tegangan relatif rendah yaitu 5 V sehingga mudah dan aman digunakan.

## 2.7 Standar Referensi Profil Bau Penentuan Kesegaran

Berdasarkan Standar Nasional Indonesia SNI 2729:2013 (SNI, 2013), persyaratan mutu dan keamanan ikan segar dinilai berdasarkan skor kesegaran. Kriteria kesegaran daging ikan dengan skor ditunjukkan pada Tabel 2.14.

Tabel 2.14. Persyaratan Mutu dan Keamanan Ikan Segar dari Bau (SNI, 2013)

No	Kondisi Bau	Skor
1	Bau sangat segar, spesifik spesies tuna kuat	9
2	Bau segar, spesifik jenis tuna	8
3	Bau segar, bau spesifik jenis tuna kurang	7

No	Kondisi Bau	Skor
4	Bau netral	6
5	Sedikit bau asam	5
6	Bau asam yang kuat	3
7	Bau busuk yang kuat	1

Berdasarkan Standar Nasional Indonesia SNI 2729:2013, daging ikan kondisi segar memiliki skor minimal 7. Kriteria bau daging ikan segar didefinisikan dengan kondisi daging ikan yang lendirnya tidak berbau, bau asin/bau laut pada usus (tidak ada bau amonia atau bau amis) (Department of Fisheries Government of Western Australia, 2002).

Sedangkan untuk fitur tekstur, menurut Standar Nasional Indonesia SNI 2729:2013 (SNI, 2013), daging ikan segar dinilai berdasarkan skor sesuai dengan profil tekstur. Kriteria kesegaran daging ikan berdasarkan tekstur dengan skor ditunjukkan pada Tabel 2.15.

Tabel 2.15. Persyaratan Mutu dan Keamanan Ikan Segar Berdasarkan Tekstur

No	Kondisi Tekstur	Skor
1	Padat, kompak, sangat elastis	9
2	Padat, kompak, elastis	8
3	Agak lunak, agak elastis	7
4	Agak lunak, sedikit kurang elastis	6
5	Agak lunak, kurang elastis	5
6	Lunak bekas jari terlihat dan sangat lambat hilang	3
7	Sangat lunak, bekas jari tidak hilang	1

Menurut Standar Nasional Indonesia SNI 2729:2013, daging ikan kondisi segar memiliki skor minimal 7. Kriteria daging ikan segar berdasarkan tekstur memiliki ciri tekstur daging ikan kencang, lembab dan elastis, tidak terpisah, melekat erat pada tulang (Department of Fisheries Government of Western Australia, 2002).

Kandungan lemak pada daging ikan berdasarkan tingkatan kualitas daging ikan menurut Robert DiGregorio (DiGregorio, 2012) ditunjukkan pada Tabel 2.16.

Tabel 2.16. Kualitas Grade Daging Tuna Berdasarkan Kandungan Lemak

No	Grade	Deskripsi
1	#1	Memiliki kandungan lemak yang tinggi. Ikan tuna dengan dinding perut yang tebal kemungkinan besar akan menjadi ikan berlemak
2	#2+	Memiliki sedikit lemak, lebih sedikit dibandingkan dengan kualitas grade #1
3	#2	Memiliki kandungan lemak sangat minim dan lemak tidak terlihat jelas pada bagian tengah daging atau bagian ekor
4	#3	Tidak ada kandungan lemak pada daging tuna.

Berdasarkan karakteristik kualitas *grade* ikan tuna, Bartam (1996) mengelompokkan kualitas *grade* berdasarkan (Bartam et al., 1996) yaitu:

- a. Karakteristik yang dapat diamati yang mempengaruhi harga, yaitu: spesies, ukuran, cacat tubuh
- b. Umur simpan yaitu evaluasi kesegaran atau masa pakai ikan
- c. Kualitas otot daging seperti penampilan tekstur, warna daging, kecerahan dan kandungan minyak pada daging.

Adapun sistem penentuan *grade* ikan tuna menurut (Bartam et al., 1996) dapat dilihat pada Tabel 2.17.

Tabel 2.17. Karakteristik Penentuan *Grade* Daging Tuna(Bartam et al., 1996)

No	Grade	Karakteristik
1	1+(A+)	Ukuran ikan besar, segar, kencang dengan otot merah cerah, sangat tembus cahaya dan memiliki kandungan lemak/minyak tinggi
2	2+ (A)	Ukuran ikan besar, segar, kencang dengan otot merah cerah, sangat tembus cahaya dan sedikit atau tidak ada kandungan lemak yang terlihat
3	2 (B)	Kondisi segar dan kencang, dengan otot yang berwarna merah hingga merah kecoklatan tetapi tidak tembus cahaya, tidak ada kandungan lemak
4	3 (C)	Daging berwarna terlalu coklat, terlalu pucat atau terlalu lunak untuk digunakan, ukurannya atau berat ikan lebih kecil (< 35 pound)
5	4 (D)	Ikan biasanya permukaannya rusak, ototnya lembek atau warnanya berubah, daging berwarna sangat pucat dan berwarna coklat atau buram,digunakan untuk produk tuna loin beku, asap dan tuna kering

Menurut Bartam (1996) perbandingan sistem penentuan kualitas *grade* ikan tuna Hawaii dan Jepang dijelaskan pada Tabel 2.18.

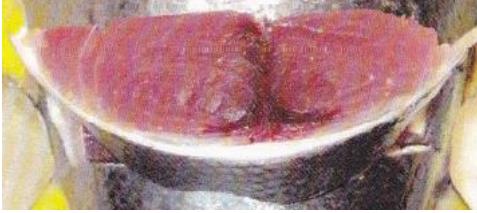
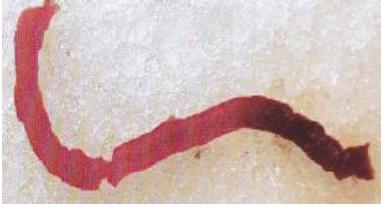
Tabel 2.18. Perbandingan Sistem Kualitas *Grade* Ikan Tuna (Bartam et al., 1996)

No	US	Hawaii	Japan
1	Grade 1	Grade 1+	Grade A
2	Grade 2+	Grade 2+	Grade B
3	Grade 2	Grade 2	Grade C
4	Grade 3	Grade 3	Reject
5	Grade 4	Grade 4	Reject

## 2.8 Kualitas *Grade* Daging Tuna Berdasarkan Kandungan Lemak dan Spektrum Warna

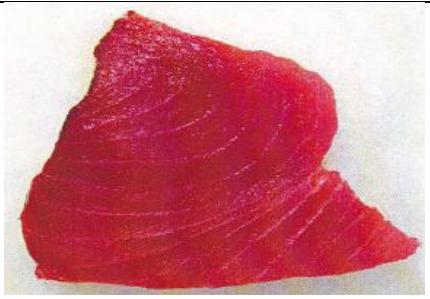
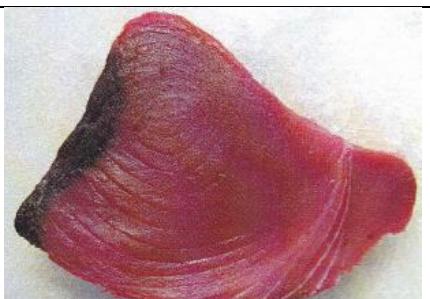
Penentuan kualitas *grade* daging tuna ditentukan berdasarkan spektrum warna daging tuna dan potongan ekor. Tabel 2.19 menunjukkan kualitas *grade* daging tuna berdasarkan spektrum warna.

Tabel 2.19. Kualitas *Grade* Daging Tuna Berdasarkan Warna Potongan Ekor dan Sampel Inti (DiGregorio, 2012)

No	Grade	Warna Potongan Ekor	Sampel Inti
1	#1		
2	#2+		
3	#2		
4	#3		

Tabel 2.19 menunjukkan warna setiap *grade* pada potongan ekor dan sampel inti. *Grade #1* menunjukkan warna merah cerah dan lapisan lemak yang tebal yang terletak di antara daging ekor dan kulit. Sampel inti menunjukkan warna merah cerah dan tekstur yang elastis. *Grade #2+* menunjukkan warna merah kehitaman tidak secerah *grade #1* dan lapisan lemak yang tipis yang terletak di antara daging ekor dan kulit. Sampel inti menunjukkan warna merah lebih pudar dibandingkan dengan *grade #1*. Tekstur sampel inti kurang elastis di bandingkan dengan *grade #1*. Sedangkan *grade #2* menunjukkan warna merah yang lebih pudar dibandingkan dengan *grade #2+* dan tidak merata seperti warna merah bata sampai magenta. *Grade #2* tidak tampak kembali lapisan lemak yang terletak diantara daging ekor dan kulit. Sampel inti menunjukkan warna merah lebih pudar dibandingkan dengan *grade #2+*. Tekstur sampel inti mudah rapuh dan tidak elastis. *Grade #3* menunjukkan warna coklat kusam dan gelap kehitaman. Tidak tampak kembali lapisan lemak yang terletak diantara daging ekor dan kulit. Sampel inti menunjukkan warna merah kehitaman dibandingkan dengan *grade #2*.

Tabel 2.20. Kualitas *Grade* Daging Tuna Berdasarkan Spektrum Warna (DiGregorio, 2012)

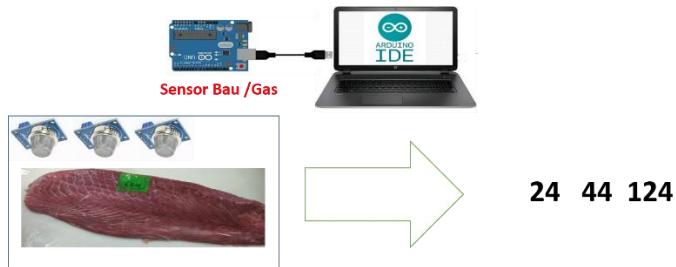
No	Grade	Warna Loin	Warna Potongan Steak
1	#1		
2	#2+		

No	Grade	Warna Loin	Warna Potongan Steak
3	#2		
4	#3		

Tabel 2.20 menunjukkan ciri kualitas *grade* berdasarkan warna daging tuna. *Grade #1* menunjukkan warna daging tuna cerah merah dan mengkilat. Sedangkan *Grade #2+* dengan ciri daging loin berwarna merah agak terang dan mungkin sedikit lebih gelap atau bahkan sedikit lebih terang dan warna merahnya sedikit lebih pudar dari warna *grade #1*. *Grade #2* menunjukkan warna agak gelap dan mungkin hitam. Warna merah *grade #2* memiliki warna tidak merata dan lebih pudar dan seperti warna merah bata sampai warna magenta. Sedangkan grade #3 memiliki warna agak gelap kehitaman berupa warna krem pucat kusam dan suram.

## 2.10 Akuisisi Profil Bau

Akuisisi profil bau dari tuna loin menggunakan sensor gas MQ-4 yang mendeteksi bau gas metana, MQ-136 untuk mendeteksi gas hidrogen sulfida, dan MQ-137 untuk mendeteksi gas amoniak dan asam organik pada tuna loin(ShowRange, n.d.).

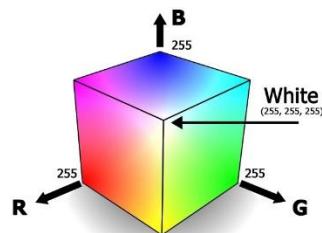


Gambar 2.11 Ilustrasi Pengukuran Profil Bau Tuna Loin

Gambar 2.11 menunjukkan ilustrasi pengukuran profil bau tuna loin. Saat pengukuran profil bau daging tuna loin dengan sensor MQ, diperoleh 3 deret nilai hasil pengukuran dari sensor.

## 2.11 Ruang Warna RGB dan HSV

Pengolahan citra menggunakan informasi ruang warna untuk membantu analisis citra misalnya identifikasi objek atau ekstraksi citra. Ruang warna RGB adalah suatu ruang warna yang terdiri atas 3 buah warna yaitu merah (*red*), hijau (*green*), dan biru (*blue*), yang ditambahkan dengan berbagai cara untuk menghasilkan berbagai jenis warna (Hestiningsih, 2008)(Pamungkas, 2016). Kegunaan utama ruang warna RGB adalah untuk menampilkan citra/gambar dalam perangkat elektronik, seperti televisi dan komputer, walaupun juga telah digunakan dalam fotografi biasa.

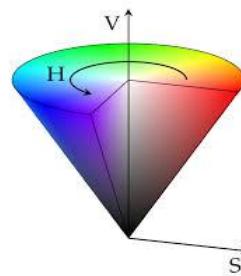


Gambar 2.12 Kubus Warna RGB  
(Sumber: Pamungkas, 2016)

Gambar 2.12 menunjukkan ruang warna RGB dimana garis diagonal ruang menyatakan warna *grayscale*, yakni warna piksel dalam rentang gradasi warna hitam dan putih yang dapat diperoleh dengan mengalikan ketiga komponen warna pokok merah, hijau dan biru dengan suatu koefisien yang jumlahnya satu.

Ruang warna HSV mendefinisikan warna dalam terminologi *Hue*, *Saturation* dan *Value*. Ruang warna HSV menggunakan warna yang sama dengan warna yang

ditangkap oleh mata (indera) manusia. Sedangkan warna yang dibentuk model lain seperti RGB merupakan hasil campuran dari warna-warna primer (Kadir & Susanto, 2013)(Oni et al., 2021). *Hue* menyatakan warna sebenarnya, digunakan untuk membedakan warna-warna dan menentukan kemerahan (*redness*), kehijauan (*greeness*) dari spektrum warna cahaya. *Saturation* menyatakan tingkat kemurnian suatu warna, yaitu mengindikasikan seberapa banyak warna putih diberikan pada warna. *Value* adalah atribut yang menyatakan banyaknya cahaya yang diterima oleh mata tanpa memperdulikan warna. Ruang warna HSV ditunjukkan pada Gambar 2.13.



Gambar 2.13 Ruang Warna HSV  
(Sumber: Pamungkas, 2016)

## 2.11 Akuisisi Fitur Tekstur Citra

Tekstur merupakan representasi frekuensi perubahan rona pada citra (Lillesand dan Kiefer, 1979) atau pengulangan rona kelompok obyek yang terlalu kecil untuk dibedakan secara individual (Estes dan Simonett, 1975). Tekstur merupakan bentuk atau nilai raba permukaan benda atau gambar baik itu benda nyata atau semu. Suatu permukaan memiliki kemungkinan sifat kasar halus keras atau lunak. Terdapat berbagai metode yang digunakan untuk memperoleh fitur tekstur yaitu (Atmaja, 2017):

a. Metode statistis

Metode statistis menggunakan perhitungan statistika untuk membentuk fitur. Contoh yang termasuk sebagai metode statistis yaitu GLCM dan Tamura.

b. Metode struktural

Metode struktural menjabarkan susunan elemen ke dalam tekstur. Contoh metode struktural adalah *Shape Grammar* (Petrou dan Sevilla, 2006).

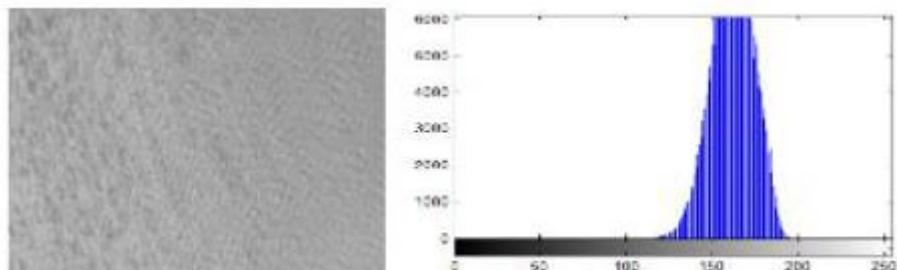
c. Metode spektral

Metode spektral adalah metode yang didasarkan pada domain frekuensi spasial.

Contoh metode spektral adalah distribusi energi domain *Fourier*, *Gabor*, dan filter *Laws*.

### 2.11.1 Tekstur Histogram

Metode untuk mendapatkan tekstur dengan menggunakan histogram.

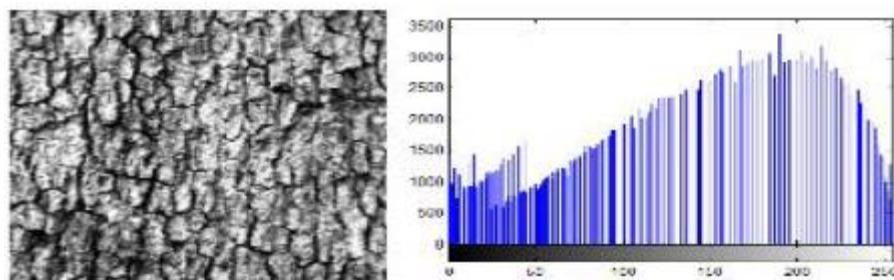


Gambar 2.14 Tekstur Halus

(Sumber: <https://repository.unikom.ac.id/64404/1/CV-6-%20Ekstraksi%20Fitur%20Tekstur.pdf>)

a. Tekstur Halus

b. Histogram Tekstur Halus



Gambar 2.15 Tekstur Kasar

(Sumber: <https://repository.unikom.ac.id/64404/1/CV-6-%20Ekstraksi%20Fitur%20Tekstur.pdf>)

a. Tekstur Kasar

b. Histogram Tekstur Kasar

Gambar 2.14 menunjukkan citra dengan tekstur halus yang memiliki daerah perubahan intensitas yang sempit. Gambar 2.15 menunjukkan citra yang kasar memiliki kontras yang tinggi, ditandai dengan jangkauan intensitas yang lebar. Tekstur menunjukkan ukuran kehalusan kekasaran intensitas citra (Atmaja, 2017).

### **2.11.2 Tekstur Gray Level Co-occurrence Matrix**

*Gray Level Co-occurrence Matrix* (GLCM) sebagai metode statistik untuk menghitung tekstur fitur dengan mempertimbangkan hubungan spasial dari piksel abu-abu dari suatu gambar. GLCM sebagai metode ekstraksi ciri berdasarkan tekstur. Matriks GLCM menunjukkan tekstur gambar melalui perhitungan beberapa pasang piksel yang memiliki hubungan spasial dan hubungan nilai tertentu dalam suatu citra. GLCM dibuat dengan menghitung frekuensi piksel dengan intensitas i yang bertemu piksel dengan intensitas j dalam tertentu hubungan spasial. Untuk memperoleh tekstur citra digunakan perhitungan tekstur pada orde kedua melalui hubungan jarak ketetanggaan antara 2 piksel dan orientasi arah sudut  $0^\circ$ ,  $45^\circ$ ,  $90^\circ$ ,  $135^\circ$  dapat dikombinasi serta jarak ketetanggaan (Kadir dan Susanto, 2013).

Terdapat beberapa langkah pembuatan matrix GLCM yaitu:

1. Menentukan nilai awal untuk matriks GLCM suatu pasangan piksel melalui arah sudut dan jarak ketetanggaan.
2. Membuat matriks *framework* berdasarkan jumlah pasangan piksel.
3. Pembentukan matriks GLCM yang simetris (penjumlahan *co-occurrence matrix* dengan transpose matrix)
4. Kemudian matriks simetris dinormalisasi, menghasilkan nilai matrix antara 0 sampai 1.
5. Selanjutnya matriks tersebut digunakan untuk menghitung fitur tekstur.

GLCM menyediakan informasi tentang tekstur gambar (Asmara et al., 2017) yaitu :

1. Kontras  
Kontras adalah perbedaan piksel dari nilai di sebelahnya. Apabila suatu piksel dengan piksel tetangganya mempunyai nilai intensitas yang berdekatan, maka kontras tekstur sangat rendah.
2. Korelasi  
Korelasi adalah fitur yang menghitung korelasi suatu piksel dengan piksel lain yang dapat dihitung. Rentang nilai korelasi antara -1 dan 1.
3. Homogenitas  
Homogenitas mengukur tingkat kesamaan variasi dalam intensitas keabuan citra pada matriks *co-occurrence*. Homogenitas bernilai tinggi jika pasangan piksel

mempunyai nilai keabuan yang seragam. Homogenitas dihitung menggunakan persamaan (3), dengan range nilai antara 0 sampai 1.

### 3. Energi

Energi adalah karakteristik untuk melihat tingkat keseragaman tekstur. Jika semakin tinggi nilai energi, maka tingkat homogenitas tekstur tinggi dan variasi intensitas dalam citra mengecil. GLCM menggunakan perhitungan tekstur pada orde kedua, yang memperhitungkan hubungan antar pasangan dua piksel citra asli (Hall Beyer, 2007). Untuk mendapatkan fitur GLCM dapat menggunakan lima besaran berupa *angular second moment* (ASM), kontras, *inverse different moment* (IDM), entropi, dan korelasi. ASM merupakan ukuran homogenitas citra(Pamungkas, 2018). Besaran tersebut dijelaskan sebagai berikut:

- a. ASM merupakan ukuran homogenitas citra. ASM memiliki nilai tinggi ketika citra memiliki homogenitas yang baik atau nilai piksel yang hampir serupa(Pamungkas, 2018).

- b. Kontras, menunjukkan ukuran intensitas aras keabuan antara piksel dengan piksel lainnya dengan lokasi relatif. Kontras memiliki batas nilai dari 0 hingga pangkat 2 dari panjang matriks GLCM simetris. Pada citra dengan elemen piksel yang bernilai sama secara keseluruhan maka nilai kontras = 0 (Pamungkas, 2018).

- c. IDM menunjukkan homogenitas lokal. IDM berkaitan dengan kontras. Bobot IDM berkebalikan dengan kontras (Pamungkas, 2018)

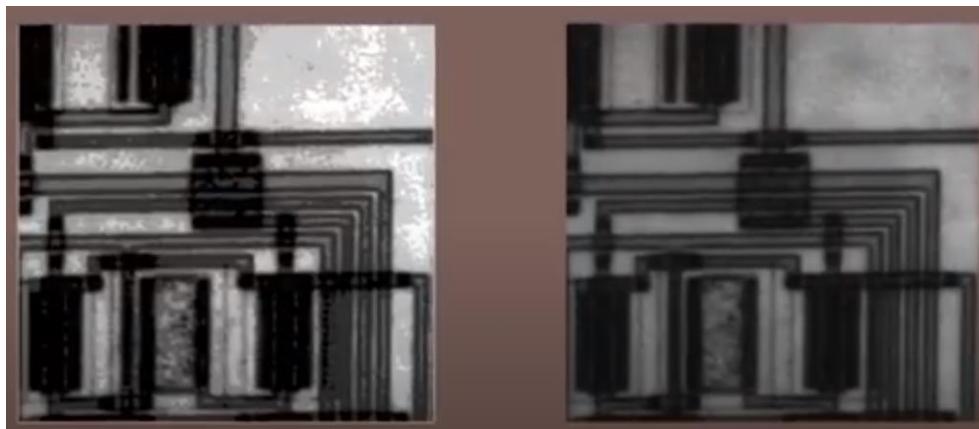
- d. *Entropy* menunjukkan ketidakteraturan aras keabuan dalam suatu citra. Nilai entropi akan semakin tinggi jika nilai elemen piksel citra semakin acak (Pamungkas, 2018)

e. Korelasi mengukur ketergantungan linier dari aras keabuan dalam ketetanggaan piksel citra (Pamungkas, 2018).

$$\text{Korelasi} = \sum_{i=1}^L \sum_{j=1}^l \frac{(i-\mu i') * (j-\mu j') * GLCM(i,j)}{\sigma i' * \sigma j'} \quad \dots \dots \dots (5)$$

dengan

Contoh hasil tekstur *Gray Level Co-occurrence Matrix* dapat dilihat pada Gambar 2.16



Gambar 2.16 Contoh Hasil Tekstur *Grey Level CoOccurrence Matrix*

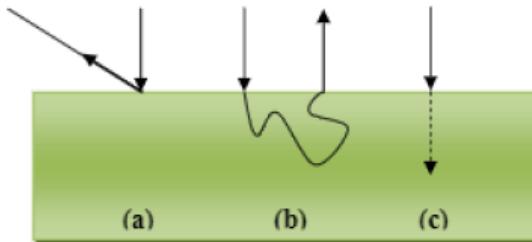
(Sumber: <https://repository.unikom.ac.id/64404/1/CV-6-%20Ekstraksi%20Fitur%20Tekstur.pdf>)

## 2.12 Metode Spektrometri *Near Infrared (NIR)*

Metode *near infrared* (NIR) merupakan salah satu teknik yang menggunakan panjang gelombang infra merah pada spektrum elektromagnetik antara 700 sampai 2500 nm (Dryden, 2003). Hal yang terpenting penggunaan metode NIR (reflektan dan absorban elektromagnetik) adalah mampu menganalisis komponen, mendeteksi kualitas, dan mendeteksi tingkat kematangan (Mohsenin, 1984). Metode NIR memiliki konsep yang sama dengan cara kerja retina mata yaitu cahaya tampak diterima oleh mata sesuai dengan besarnya pantulan seperti warna dihasilkan dari cahaya yang dipantulkan dari suatu objek. Setiap bahan memiliki spektrum unik dari pantulan NIR

yang dihasilkan dari efek penyebaran, penyerapan dan pantulan cahaya oleh bahan yang dideteksi, dalam bentuk spektrum pantulan. Radiasi inframerah menyebabkan senyawa organik mengalami rotasi dan getaran (vibrasi) ikatan *inter-atomic* (Osborne et al., 1993).

Cahaya *near infrared* yang mengenai bahan memiliki energi yang kecil dan hanya menembus sekitar satu milimeter permukaan bahan, tergantung dari komposisi bahan tersebut. Jika cahaya mengalami penyebaran, spektrum tetap mengandung informasi dari penyerapan permukaan bahan (Dryden, 2003). Variasi ukuran dan suhu partikel sampel mempengaruhi penyebaran radiasi infra merah pada saat melewati sampel. Partikel berukuran besar tidak dapat menyebarkan radiasi infra merah sebanyak partikel kecil. Makin banyak radiasi yang diserap dapat memberikan nilai absorban yang tinggi dan berdampak pada semakin besar pada panjang gelombang yang diserap (Dryden, 2003).



Gambar 2.17 Diagram Penampakan *Specular*  
 (a) *diffuse* (b) *reflectances* (c) *absorption radiasi near infrared* dari sebuah sampel (Sumber: Dryden, 2003)

Gambar 2.17 menunjukkan diagram penampakan radiasi *near infrared* dari sebuah sampel (Dryden, 2003). Metode NIR memiliki beberapa kelebihan, antara lain dapat menurunkan biaya tenaga kerja penganalisis komposisi, penggunaan sampel preparat yang sederhana, waktu yang cepat dalam pendugaan komposisi, analisis contoh yang tidak merusak (*non-destructive*), tidak menggunakan bahan-bahan kimia (analisis yang bebas limbah), dan dapat menganalisis komposisi dengan kecepatan dan ketepatan tinggi (Williams, 1987).

Sensor yang digunakan untuk mengenali komposisi sebuah benda, buah atau bahan makanan salah satunya menggunakan sensor *Sparkfun Spectroscopy AS7263* seperti ditunjukkan pada Gambar 2.18.



Gambar 2.18. Sensor *Sparkfun Spectroscopy AS 7263*  
(Sumber: Electronics, n.d.)

Sensor *Sparkfun Spectroscopy* adalah sensor optik yang dikenal sebagai spektrofotometer. AS7263 memiliki kemampuan untuk mengukur dan menggambarkan karakter material yang berbeda menyerap dan memantulkan 6 frekuensi cahaya yang berbeda. Spektrometer AS7263 mendeteksi panjang gelombang dalam kisaran yang terlihat pada cahaya dengan panjang gelombang 610, 680, 730, 760, 810, dan 860 nm. Sensor ini menerangi objek yang diukur melalui pembacaan spektroskopi yang lebih akurat. (Electronics, n.d.). Adapun spesifikasi teknis dari Sensor AS-7263 ditunjukkan pada Tabel 2.21.

Tabel 2.21. Spesifikasi Teknis Sensor AS-7263

No	Kategori	Deskripsi
1	<i>Channel Data</i>	Terdiri dari 6 <i>near-IR channels</i> yaitu 610nm, 680nm, 730nm, 760nm, 810nm dan 860nm, dengan <i>full width half max</i> = 20 nm
2	Antarmuka digital	UART atau I <sup>2</sup> C <i>slave digital interface</i>
3	Pin digital	16-bit ADC dengan akses digital
4	Tegangan operasional	I <sup>2</sup> C interface dari 2.7V sampai 3.6V
5	Jangkauan temperature	-40°C sampai 85°C
6	Filter <i>Near Infrared</i>	Filter berupa <i>silicon interference filter</i>
7	Jenis Konektor	2 unit konektor <i>Qwiic</i>

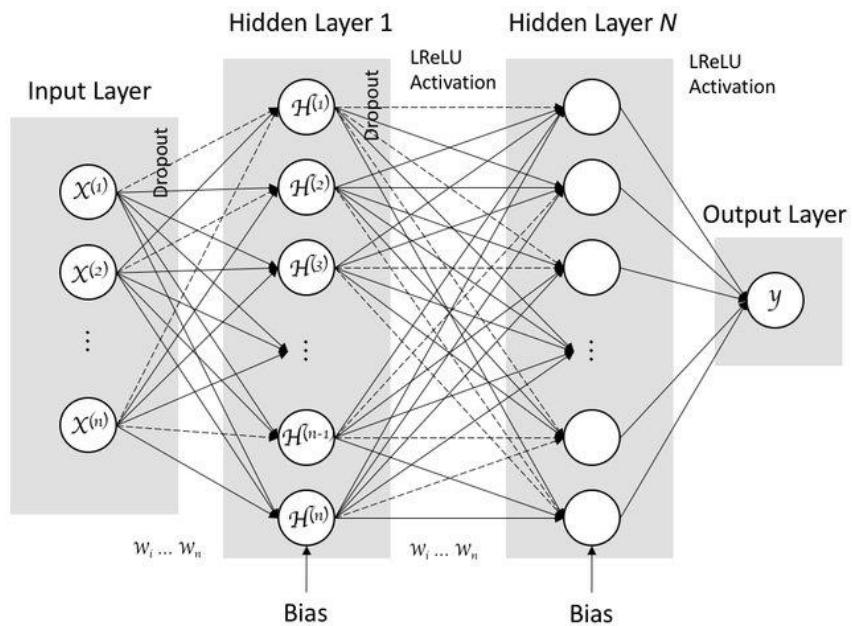
Keunggulan dari gelombang *near infrared* menurut Osborne et al. (1993) dalam analisis bahan makanan adalah memiliki tingkat ketepatan, kecepatan, dan kemudahan dalam melakukan percobaan (prosedur tidak rumit). Implementasi *near infrared* (NIR) telah banyak digunakan di Eropa, Amerika Utara, Asia, Australia, dan New Zealand baik dalam bidang industri maupun dalam bidang pertanian. Sedangkan

di Indonesia sendiri, metode ini belum banyak digunakan terutama di dalam bidang pertanian. Berdasarkan sifat absorban dan reflektan dari energi radiasi yang dipancarkan, metode NIR dapat digunakan untuk menduga komposisi kimia suatu bahan, terutama untuk identifikasi komposisi bahan pangan, pertanian, kedokteran, farmasi, dan industri kimia. Untuk bahan pangan dan hasil pertanian seperti kedelai, jagung, beras, daging, ikan, hortikultura, metode NIR dapat digunakan untuk penentuan komposisi kimia seperti kadar air, lemak, asam, gula, protein dan berbagai senyawa lainnya. Selain itu metode NIR digunakan dalam industri susu, yaitu untuk menentukan kandungan protein, lemak, dan kadar air dalam susu murni dan menentukan kandungan protein yang terdapat dalam tepung susu skim.

Penelitian sebelumnya dari Sulistyo (2021) melakukan evaluasi kandungan kimia buah jeruk siam secara non-destruktif menggunakan *Near Infrared Spectrometer* portabel dengan sensor AS7263 dan aplikasi *Neural Network Ensemble* (NNE) dengan *genetic algorithm* (GA) untuk optimasi. Enam *channel NIRS portabel* digunakan sebagai input NNE. NNE yang dikembangkan terdiri atas empat buah *Backpropagation Neural Network* (BPNN) dengan dua buah lapisan tersembunyi dan kombinasi *transfer function* yang berbeda-beda. Keluaran dari keempat BPNN ini digabung untuk menghasilkan keluaran NNE yang baru dan dioptimasi menggunakan algoritma genetika. Karakteristik kimia buah jeruk yang diestimasi adalah total padatan terlarut (TPT) dan vitamin C (Sulistyo et al., 2021). Penelitian dari Zhang (2020) meneliti mengenai lemak dan kelembaban ikan salmon menggunakan *near-infrared hyperspectral imaging*. Sepuluh fitur tekstur dari gambar komponen utama diperoleh dengan menggunakan statistik histogram (HS) dan metode *gray level co-occurrence matrix* (GLCM). Tiga jenis model (PLS, MLR dan LS-SVM) digunakan membandingkan jenis input yang berbeda yaitu menggunakan karakteristik panjang gelombang saja, parameter tekstur saja dan kombinasi masing-masing panjang gelombang dan tekstur. Berdasarkan hasil perbandingan semua model, model LS-SVM dengan karakteristik panjang gelombang dan tekstur memberikan akurasi prediksi yang paling tinggi (H. Zhang et al., 2020).

### 2.13 Deep Learning Metode Convolutional Neural Network

Jaringan neural konvolusional dapat memiliki puluhan atau ratusan lapisan yang masing-masing belajar mendeteksi fitur citra yang berbeda. Filter diterapkan ke setiap citra pelatihan pada resolusi yang berbeda, dan keluaran dari setiap citra yang digunakan sebagai masukan ke lapisan berikutnya. *Convolutional Neural Network* terdiri dari *input layer*, *hidden layer* dan *output layer* (Vedaldi & Lenc, 2015). *Input layer* berupa ekstraksi ciri dari data pembelajaran atau data yang diuji, sedangkan *hidden layer* merupakan koefisien pembelajaran yang dibentuk dari proses pembelajaran data input. Sedangkan *output layer* merupakan hasil atau keluaran dari data input setelah di konvolusi pada *hidden layer*. Jaringan ini akan melakukan pembelajaran dari banyak data *learning* yang diinputkan sampai tercapai tingkat *error* yang minimum. Gambar 2.19 menunjukkan jaringan konvolusional *deep learning*.



Gambar 2.19. Jaringan Konvolusional *Deep Learning*  
(Sumber: Kim, 2017)

#### 2.13.1 Konvolusi CNN

Konvolusi sebagai sebuah proses dimana citra dimanipulasi dengan menggunakan *mask* eksternal atau *subwindows* untuk menghasilkan citra yang baru(Rohim et al., 2019). Secara matematis menurut Madenda (2013) konvolusi adalah jumlah total dari hasil kali antara setiap elemen yang bersesuaian (memiliki

posisi koordinat yang sama) dalam dua matriks atau dua vector (Madenda, 2013). Ilustrasi konvolusi CNN ditunjukkan pada Gambar 2.20.

$$\begin{array}{|c|c|c|c|c|c|} \hline
 3 & 0 & 1 & 2 & 7 & 4 \\ \hline
 1 & 5 & 8 & 9 & 3 & 1 \\ \hline
 2 & 7 & 2 & 5 & 1 & 3 \\ \hline
 0 & 1 & 3 & 1 & 7 & 8 \\ \hline
 4 & 2 & 1 & 6 & 2 & 8 \\ \hline
 2 & 4 & 5 & 2 & 3 & 9 \\ \hline
 \end{array}
 \quad *
 \quad
 \begin{array}{|c|c|c|} \hline
 1 & 0 & -1 \\ \hline
 1 & 0 & -1 \\ \hline
 1 & 0 & -1 \\ \hline
 \end{array}
 \quad =
 \quad
 \begin{array}{|c|c|c|c|} \hline
 -5 & -4 & 0 & 8 \\ \hline
 -10 & -2 & -2 & 3 \\ \hline
 0 & -2 & -4 & -7 \\ \hline
 -3 & -2 & -3 & -16 \\ \hline
 \end{array}$$

3 x 3

4 x 4

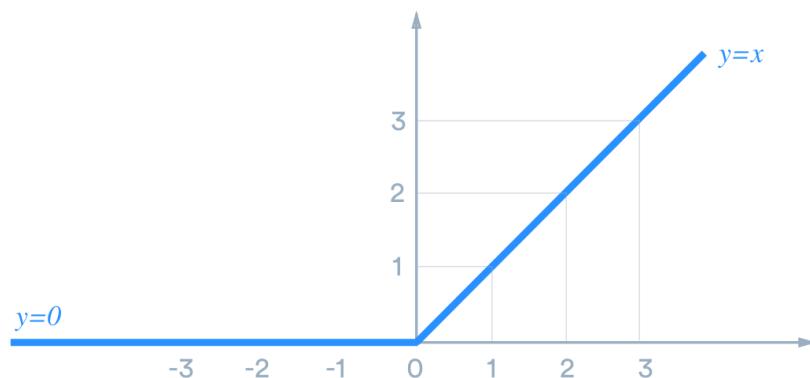
Gambar 2.20. Contoh Konvolusi  
(Sumber: Kim, 2017)

### 2.13.2 Pooling CNN

*Pooling* adalah proses mereduksi ukuran sebuah data citra(Rohim et al., 2019). Dalam pengolahan citra, *pooling* juga bertujuan untuk meningkatkan invariansi posisi dari fitur serta mempercepat komputasi dan mengontrol terjadinya *overfitting*.

### 2.13.3 ReLu Aktivasi

*Rectified linear unit*, yang dikenal sebagai ReLU, sebagai cara paling umum untuk menerapkan non-linearitas ke dalam jaringan saraf, melalui fungsi max (0, x). Fungsi aktifasi ReLu dapat di lihat pada persamaan 10 yang ditunjukkan pada Gambar 2.21.



Gambar 2.21. Fungsi Aktivasi *Rectified Linear Unit*

#### 2.13.4 Confusion Matrix

*Confusion matrix* adalah salah satu metode yang digunakan untuk mengevaluasi metode klasifikasi. *Confusion matrix* ditunjukkan pada Tabel 2.22.

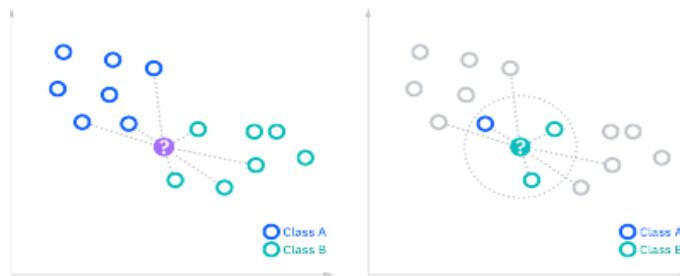
Tabel 2.22. *Confusion Matrix* (Kim, 2017)

		Kelas Prediksi	
		Positif	Negatif
Kelas Aktual	Positif	TP	FN
	Negatif	FP	TN

Nilai *True Negative* (TN) adalah data yang di klasifikasi dengan tepat sebagai keluaran negatif atau salah. *True Positive* (TP) adalah data yang diklasifikasi dengan tepat sebagai keluaran positif atau benar. *False Positive* (FP) adalah data yang diklasifikasi dengan kurang tepat apabila keluaran berupa positif atau benar. *False Negative* (FN) adalah data yang diklasifikasi dengan kurang tepat.

#### 2.14 Algoritma *k-Nearest Neighbor*

Algoritme *k-Nearest Neighbor* (*k*-NN) adalah pengklasifikasi pembelajaran terbimbing non-parametrik, yang menggunakan kedekatan untuk membuat klasifikasi atau prediksi tentang pengelompokan sebuah titik data. Algoritma *k*-NN bekerja dengan asumsi bahwa titik yang serupa dapat ditemukan berdekatan satu sama lain. Algoritma *k*-NN bertujuan untuk mengidentifikasi tetangga terdekat dari titik *query* yang diberikan, sehingga dapat ditetapkan label kelas ke titik tersebut(IBM, n.d.).



Gambar 2.22. Ilustrasi Klasifikasi Dengan Algoritma *k*-NN (IBM, n.d.)

Gambar 2.22 menunjukkan ilustrasi klasifikasi dengan algoritma *k*-NN. Diketahui sebuah titik data *query* yang berada pada suatu posisi spasial. Selanjutnya titik data *query* di ukur jarak dengan titik data yang dekat di sekitar titik data *query*.

tersebut berupa Kelas A yang ditandai dengan titik biru dan Kelas B ditandai dengan titik hijau. Berdasarkan Gambar 2.22 diperoleh titik data query memiliki jarak lebih dekat dengan titik data hijau, sehingga titik data *query* masuk ke Kelas B.

Algoritma k-NN mensyaratkan klasifikasi sebuah titik baru dari perhitungan metrik jarak dari titik data di sekitarnya. Untuk menentukan titik data mana yang paling dekat dengan titik baru, perlu dihitung jarak antara titik baru dan titik data lainnya.

a. Jarak Euclidean

Merupakan pengukuran metrik jarak yang paling umum digunakan untuk mengukur garis lurus antara titik baru dan titik lainnya yang berdekatan, seperti ditunjukkan pada persamaan 11.

b. Jarak *Manhattan*

Merupakan metrik jarak yang mengukur nilai absolut antara dua titik. Persamaan 12 menunjukkan rumus jarak Manhattan antara titik.

c. Jarak Minkowski.

Jarak ini merupakan bentuk umum dari metrik jarak *Euclidean* dan *Manhattan*.

Jarak Euclidean diwakili oleh rumus ini ketika  $p$  sama dengan dua, dan jarak Manhattan dilambangkan dengan  $p$  sama dengan satu. Persamaan 13 menunjukkan rumus perhitungan jarak dengan algoritma Minkowski.

d. Jarak Hamming

Teknik ini digunakan dengan vektor boolean atau string, mengidentifikasi titik-titik di mana vektor tidak cocok. Algoritma ini disebut sebagai metrik tumpang tindih. Persamaan 14 menunjukkan rumus perhitungan jarak dengan algoritma Hamming,

$$x = y \quad D = 0$$

$$x \neq y \quad D \neq 1$$

Penentuan nilai  $k$  pada algoritma k-NN mendefinisikan berapa banyak tetangga sebagai hasil klasifikasi titik *query* tertentu. Misalnya, jika  $k=1$ , *instance* akan ditugaskan ke kelas yang sama dengan tetangga terdekatnya. Nilai  $k$  yang lebih rendah dapat memiliki varians yang tinggi, tetapi bias yang rendah, dan nilai  $k$  yang lebih besar dapat menyebabkan varians yang lebih rendah dan bias yang tinggi. Pilihan  $k$  bergantung pada data input karena data dengan lebih banyak *outlier* atau *noise* kemungkinan akan berkinerja lebih baik dengan nilai  $k$  yang lebih tinggi. Nilai  $k$  direkomendasikan sebagai angka ganjil untuk memudahkan dalam klasifikasi sebuah titik baru ke sebuah kelas. Algoritma k-NN dipilih dalam penelitian ini karena algoritma ini memiliki keunggulan diantaranya:

- a. Mudah diterapkan, algoritma yang sederhana dan memiliki akurasi yang baik.
- b. Mudah beradaptasi, jika sampel pelatihan baru ditambahkan, algoritma menyesuaikan untuk memasukkan data baru dalam perhitungan kelas karena semua data pelatihan disimpan ke dalam memori.
- c. Algoritma k-NN membutuhkan nilai  $k$  dan metrik jarak yang rendah jika dibandingkan dengan algoritma *machine learning* lainnya.

Adapun kelemahan menggunakan k-NN

- a. Algoritma k-NN disebut sebagai algoritma yang malas, algoritma k-NN membutuhkan lebih banyak memori dan penyimpanan data dibandingkan dengan pengklasifikasi lainnya.
- b. Tidak dapat bekerja dengan baik pada data yang berdimensi banyak.
- c. Beresiko mengalami *overfitting*, Nilai  $k$  yang lebih rendah dapat menyeragamkan data yang bervariasi, sedangkan nilai  $k$  yang lebih tinggi cenderung memperhalus nilai prediksi karena nilai tersebut rata-rata pada area atau lingkungan yang lebih luas.

Pada klasifikasi k-NN, kelas ditetapkan dari titik mayoritas di sekitar titik data tertentu. Misalnya sebuah titik ditandai sebagai sebuah kelas  $c$  jika kelas  $c$  tersebut merupakan klasifikasi yang paling banyak ditemui pada  $k$  buah tetangga terdekat titik tersebut. Klasifikasi algoritma k-NN menggunakan voting terbanyak diantara klasifikasi dari  $k$  obyek. Algoritma k-NN menggunakan klasifikasi ketetanggaan sebagai nilai prediksi dari *query instance* yang baru

## **BAB III**

### **KERANGKA BERPIKIR, KONSEP PENELITIAN DAN HIPOTESIS**

#### **3.1 Kerangka Berpikir**

Produk ikan tuna merupakan salah satu produk ekspor unggulan tujuan ke Amerika Serikat, Eropa, Jepang, dan Vietnam(Hartanto & Suharno1, 2021)(Firdaus, 2019). Pasar internasional menyediakan persyaratan wajib dipenuhi untuk dapat melakukan penetrasi ke pasar internasional berupa sertifikasi produk(Noaa, 2018). Identifikasi kualitas ikan diperlukan karena kualitas dan keamanan produk sebagai hal yang penting bagi konsumen, semakin baik kualitas produk maka harga jual produk semakin baik dan keamanan pangan lebih terjamin. Beberapa kasus ditolaknya produk perikanan Indonesia oleh Amerika Serikat merupakan salah satu bukti masih kurangnya pengelolaan keamanan pangan di Indonesia(Humas BRSDM, 2021). Kondisi yang diamati pada perusahaan pengolahan ikan tuna, penentuan kualitas *grade* ikan masih ditentukan secara manual oleh operator *checker* dengan mengambil irisan daging bagian ekor dan sampel inti dan mengamati ciri fisik sampel ikan tuna dengan indera manusia (*sensory*) dan melihat kondisi tekstur, mencium bau ikan, dan warna daging ikan. Pengecekan kualitas tuna oleh *checker* menggunakan batang besi (*spike*) yang ditancapkan ke tubuh ikan untuk mengambil irisan daging bagian ekor ikan tuna(Sidik et al., 2013). Ikan selanjutnya dipotong menjadi tuna loin dan selanjutnya dicek dan ditentukan kualitas grade kembali untuk menentukan kualitas produk tersebut. *Grading* tuna loin secara manual (*sensory*) dapat memiliki kelemahan, hasil *grading* yang subyektif dan tidak standar, dapat beresiko penentuan *grade* yang kurang akurat akibat *human error* (faktor kelelahan).

Beberapa penelitian sebelumnya melakukan penentuan kesegaran ikan dan kualitas ikan menggunakan beberapa metode. Penelitian dari Asmara et al. (2017) mengidentifikasi kesegaran daging sapi berdasarkan citra dengan ekstraksi fitur warna dan tekstur citra menggunakan *Gray Level Co-Occurrence Matrix* (GLCM), klasifikasi kesegaran daging sapi menggunakan *Naïve Bayes* (Asmara et al., 2017). Selanjutnya penelitian dari Dwiyanto et al. (2018) mengembangkan alat pendekripsi kesegaran ikan berdasarkan nilai warna RGB yang didapatkan dari sensor warna mata berbasis ATMega 328, proses klasifikasinya menggunakan metode *k-Nearest Neighbor*

(Dwiyanto et al., 2018). Penelitian dari Pakaya & Suleman (2018) melakukan pengelompokan kualitas daging ikan tuna dengan *k-means* berbasis histogram derajat keabuan. Penelitian dari Ramadhan & Setiyono (2019) melakukan pengolahan citra untuk mengetahui tingkat kesegaran ikan menggunakan metode transformasi *wavelet* diskrit dan segmentasi k-NN. Penelitian dari Kumar (2020) yang mengakuisisi data menggunakan *sensor gas array* dan mengklasifikasi kualitas ikan menggunakan *Artificial Neural Network* (ANN). Penelitian dari W. Zhang et al. (2021) menggunakan *hyperspectral imaging* (HSI) dan data multivariat untuk mengidentifikasi kesegaran ikan, dan menggunakan algoritma MLSR dan PLSR untuk mengkalibrasi dan memprediksi seluruh spektrum. Penelitian dari Agustyawan (2021) melakukan pengolahan citra untuk membedakan ikan segar dan tidak segar menggunakan *convolutional neural network*. Penelitian dari Naimullah et al. (2020) meneliti klasifikasi kualitas *grade* tuna berdasarkan fitur warna dan tekstur menggunakan histogram warna dan *gray level co-occurrence matrix*. Citra daging tuna di *pre-processing* ke dalam ruang warna RGB ke HSV, selanjutnya di normalisasi histogram. Fitur citra dilatih dengan algoritma *support vector machine* (SVM) dan diklasifikasikan ke dalam 3 kelas grade yaitu A, B dan D dengan akurasi 81.6%. Penelitian dari Buniyamin et al. (2011) melakukan deteksi lemak ikan tanpa merusak sampel dengan sensor *infrared*. Penelitian dari Prasant et al. (2019) mengembangkan *spectrophotometer* portabel berbiaya rendah dengan menggunakan sensor *near infrared* untuk mendeteksi dan menganalisa kualitas susu. (H. Zhang et al., 2020) menentukan kandungan minyak dan kelembaban ikan salmon filet dengan tanpa merusak sampel menggunakan *near-infrared hyperspectral imaging* yang dikombinasikan dengan fitur tekstur spektral menggunakan *NIR hyperspectral imaging*, dan akuisisi tekstur menggunakan algoritma GLCM. Penerapan metode NIR pada bahan pangan dan hasil pertanian seperti kedelai, jagung, beras, hortikultura, daging, dan ikan digunakan untuk penentuan komposisi kimia seperti kadar air, lemak, asam, gula, protein dan berbagai senyawa lainnya (Whitworth et al., 2010). Selain itu metode NIR digunakan dalam industri susu, yaitu untuk menentukan kandungan protein, lemak, dan kadar air. Berdasarkan sifat absorban dan reflektan dari energi radiasi yang dipancarkan, maka metode NIR dapat digunakan untuk menduga komposisi kimia suatu bahan(Shao et al., 2009)(Whitworth et al., 2010).

Berdasarkan kajian literatur diatas, penelitian sebelumnya menentuan kesegaran ikan dengan berbagai metode dan penelitian dalam penentuan kualitas *grade* ikan tuna berdasarkan fitur warna yang diolah menggunakan histogram warna dan fitur tekstur menggunakan *gray level co-occurrence matrix*. Salah satu karakteristik awal dalam penentuan kualitas ikan tuna adalah mengenali kesegaran ikan dari ciri fisik/penampakan dan bau ikan (Nasional, 2006) (Gourmets, 2021)(DiGregorio, 2012). Jika ikan dalam kondisi segar maka dapat ditentukan *grade* ikan tersebut masuk dalam kualitas ekspor atau tidak(Gourmets, 2021). Jika pada awal pengecekan, ikan dalam kondisi kurang segar, maka ikan tersebut memiliki kualitas yang tidak baik dan masuk ke dalam kualitas lokal atau *reject*(Gourmets, 2021)(Sydney Fish Market Pty Ltd, 2015).

Berdasarkan hasil sintesis teori dari kajian literatur dan studi empiris penelitian sebelumnya, maka penelitian ini membangun alat untuk mengenali kualitas *grade* daging tuna (loin) berdasarkan karakteristik yaitu kesegaran daging loin, citra warna, citra tekstur dan kandungan lemak/minyak tuna loin. Akuisisi data menggunakan perangkat berbiaya rendah, seperti penentuan kesegaran dari bau dengan sensor gas, penentuan *grade* dari akuisisi citra daging ikan dengan *web camera* dengan resolusi yang baik, untuk pengolahan citra warna dan tekstur, dan mengenali kualitas kandungan lemak/minyak daging ikan dengan menggunakan sensor spektrometer. Penentuan kualitas *grade* melalui klasifikasi dengan menggunakan algoritma *deep learning neural network*.

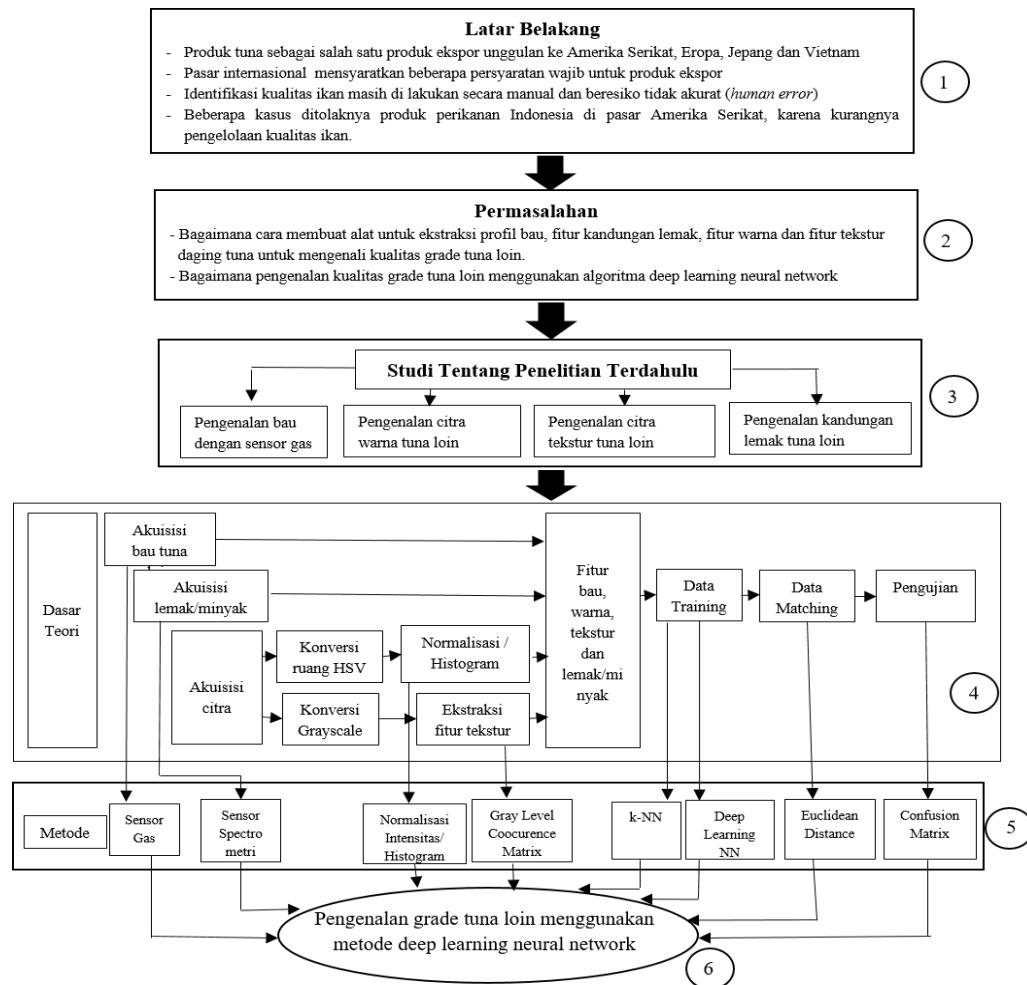
### **3.2 Konsep Penelitian**

Konsep penelitian dapat diuraikan sebagai berikut sesuai dengan urutan nomor pada Gambar 3.1.

1. Menjelaskan latar belakang penelitian dalam mengenali kualitas *grade* tuna loin yang saat ini masih dilakukan oleh operator *grader* secara manual. Produk tuna sebagai komoditi yang memiliki pangsa pasar yang besar di USA, Eropa dan Asia, sehingga penting untuk menjaga kualitas produk eksport produk ke pasar internasional terkait dengan keamanan pangan, dan prasyarat yang ditetapkan oleh negara tujuan terkait kualitas produk perikanan.
2. Permasalahan dalam penelitian adalah bagaimana membuat alat yang dapat mengenali kualitas *grade* tuna loin dengan melakukan ekstraksi fitur bau untuk

menentukan kesegaran tuna loin, fitur kecerahan warna, fitur tekstur dan fitur kandungan lemak tuna loin tersebut. Dan bagaimana cara untuk mengenali kualitas tuna loin dengan metode *deep learning neural network*.

3. Untuk menjawab permasalahan diatas, maka dilakukan *review* literatur dari penelitian sebelumnya, pustaka, jurnal, dan hasil penelitian sebelumnya yang membahas tentang penentuan kesegaran ikan, penentuan kualitas *grade* ikan dari pengolahan citra, dan penentuan kandungan minyak/lemak pada daging ikan dengan metode *spectrometry*
4. Setelah diketahui beberapa parameter yang menentukan kualitas *grading* tuna loin, maka dibutuhkan teori mengenai cara akuisisi fitur bau tuna loin, akuisisi citra warna, *pre-processing* citra, ekstraksi fitur tekstur dengan *gray level co-occurrence matrix*, proses training fitur dengan algoritma *deep learning network*, proses klasifikasi/*matching* dan pengujian model. Klasifikasi juga menggunakan algoritma *k-nearest neighbor (k-NN)* untuk membandingkan unjuk kerja kedua algoritma (mengetahui algoritma terbaik).
5. Setelah teori diperoleh dan dipahami, maka tahapan selanjutnya merancang dan membangun alat untuk mengakuisi fitur tuna loin seperti akuisisi bau dengan sensor gas, akuisisi kandungan lemak dengan sensor spektrometri, akuisisi dan *pre-processing* citra melalui ruang warna HSV dan *grayscale*, normalisasi intensitas, algoritma pelatihan fitur dengan *deep learning neural network* dan *k-nearest neighbor*, evaluasi unjuk kerja model dengan *confusion matrix*. Gambar 3.1 menunjukkan diagram konsep penelitian.



Gambar 3.1 Diagram Konsep Penelitian

Gambar 3.1 menunjukkan diagram konsep penelitian. Latar belakang penelitian ini adalah produk tuna sebagai salah satu produk ekspor unggulan ke Amerika Serikat, Jepang dan Vietnam. Beberapa persyaratan wajib yang diperlukan untuk produk ekspor pasar internasional. Beberapa kasus ditolaknya produk perikanan Indonesia di pasar Amerika Serikat karena kurangnya pengelolaan kualitas ikan. Kondisi yang ada di lapangan saat ini, penentuan kualitas daging ikan tuna masih dilakukan secara manual berdasarkan pengamatan dan penciuman bau daging sehingga beresiko tidak akurat (*human error*). Berdasarkan latar belakang tersebut, permasalahan penelitian yaitu bagaimana membangun alat untuk mendeteksi kualitas grade daging tuna loin berdasarkan bau, kandungan lemak, fitur warna dan fitur tekstur. Algoritma klasifikasi yang digunakan yaitu *deep learning neural network* dan algoritma *k-Nearest Neighbor*. Selanjutnya unjuk kerja kedua algoritma tersebut dibandingkan untuk

mengetahui unjuk kerja algoritma terbaik. Berdasarkan permasalahan tersebut, selanjutnya dilakukan literatur *review* penelitian sebelumnya. Berdasarkan studi literatur diperoleh teori yang mendasari cara untuk mengakuisisi profil bau sehingga diperoleh fitur bau, teori yang mendasari cara untuk mengakuisisi profil lemak sehingga diperoleh fitur lemak, cara untuk akuisisi citra untuk akuisisi fitur warna dan tekstur. Semua fitur digabungkan dan dilatih menggunakan algoritma, sehingga diperoleh bobot. Bobot selanjutnya di gunakan untuk data *matching* dengan fitur sampel uji. Algoritma di uji melalui proses pengujian. Teori yang mendasari akuisisi fitur menggunakan beberapa metode. Untuk akuisisi bau menggunakan sensor gas dengan pertimbangan sensor gas memiliki harga yang relatif rendah sedangkan akuisisi lemak menggunakan sensor spectrometry AS 7263. Untuk akuisisi fitur citra warna menggunakan ruang warna HSV yang dinormalisasi. Sedangkan akuisisi fitur tekstur menggunakan algoritma *Gray Level Coocurrence Matrix*. Proses pelatihan fitur menggunakan algoritma *deep learning neural network*. Algoritma klasifikasi menggunakan algoritma deep learning neural network dan algoritma *k-nearest neighbor*. Selanjutnya unjuk kerja kedua metode tersebut dibandingkan, untuk mengetahui algoritma terbaik untuk klasifikasi. Pengujian unjuk kerja algoritma menggunakan *confusion matrix*.

### 3.3 Hipotesis Penelitian

Hipotesis Penelitian merupakan jawaban sementara terhadap pertanyaan-pertanyaan penelitian. Hipotesis penelitian ini adalah kesegaran loin, warna, tekstur permukaan dan kandungan lemak berpengaruh terhadap penentuan kualitas *grade* tuna loin lebih baik. Hipotesis penelitian ini merupakan jenis hipotesis asosiatif yang merupakan dugaan ada tidaknya hubungan secara signifikan antara variabel penelitian(Sugiyono, 2018)(Hidayat, 2012). Unjuk kerja dengan algoritma *deep learning neural network* memiliki unjuk kerja lebih baik dibandingkan dengan algoritma k-NN karena *Deep Learning Neural Network* memiliki tahapan pelatihan dengan *multilayer* dan pelatihan yang berulang sampai diperoleh bobot terbaik, sehingga kemungkinan bobot pelatihan yang diperoleh lebih akurat.

## **BAB IV**

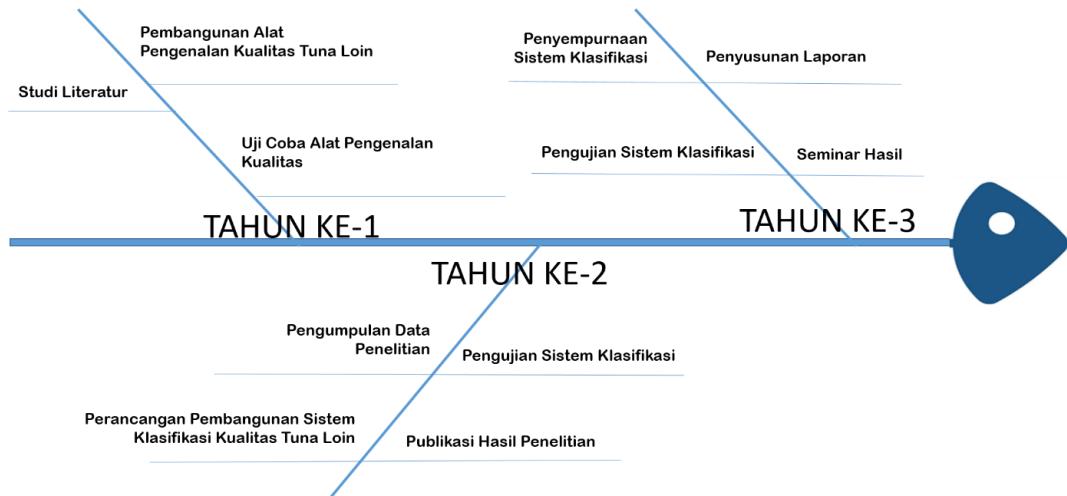
### **METODOLOGI PENELITIAN**

#### **4.1 Peta Penelitian**

Berdasarkan kerangka berpikir dan konsep pada Bab III, maka penelitian mengenai penentuan kualitas *grade* tuna loin dengan menggunakan model *neural network* dapat digambarkan pada peta penelitian seperti pada Gambar 4.1.

Berdasarkan Gambar 4.1 beberapa aspek penelitian dapat dijelaskan sebagai berikut:

1. Pada tahun ke-1 dilakukan studi literatur berupa studi tentang penelitian yang membahas tentang penentuan tingkat kesegaran daging ikan dari profil bau amoniak, hidrogen sulfida dan gas methan dengan menggunakan sensor gas, penentuan kandungan lemak pada daging dengan sensor spektrometri, akuisisi citra tuna loin untuk ekstraksi fitur warna dan fitur tekstur, klasifikasi dan cara pengujian. Tahun pertama juga dilakukan pembangunan alat untuk mengakuisisi fitur dalam mengenali kualitas ikan, menggunakan sensor gas, sensor lemak yang dihubungkan ke mikrokontroler, dan kamera yang ditempatkan di dalam kotak akrilik. Selanjutnya pada tahun pertama juga dilakukan uji coba alat yang dibangun.
2. Pada tahun ke-2 dilakukan pengumpulan data penelitian, perancangan dan pembangunan sistem klasifikasi kualitas tuna loin. Pada tahun ke-2 juga dilakukan pengujian sistem klasifikasi untuk mengetahui unjuk kerja dan akurasi sistem berdasarkan hasil pengujian sampel data. Selanjutnya pada tahun ke-2 juga direncanakan dilakukan publikasi hasil penelitian.
3. Pada tahun ke-3 dilakukan penyempurnaan sistem klasifikasi tuna loin berdasarkan hasil pengujian yang telah dilakukan pada tahun ke-2, selanjutnya dilakukan pengujian sistem tersebut, sampai diperoleh unjuk kerja dan akurasi sistem yang baik. Pada tahap akhir dilakukan penyusunan laporan penelitian, dan selanjutnya dilakukan seminar hasil penelitian.



Gambar 4.1 Peta Penelitian

## 4.2 Rancangan Penelitian

Pembangunan sistem untuk penentuan kualitas *grading* tuna loin secara umum dijelaskan dalam rancangan penelitian sebagai berikut:

### 4.2.1 Tahapan Penentuan Kualitas Grade Tuna Loin Secara Umum

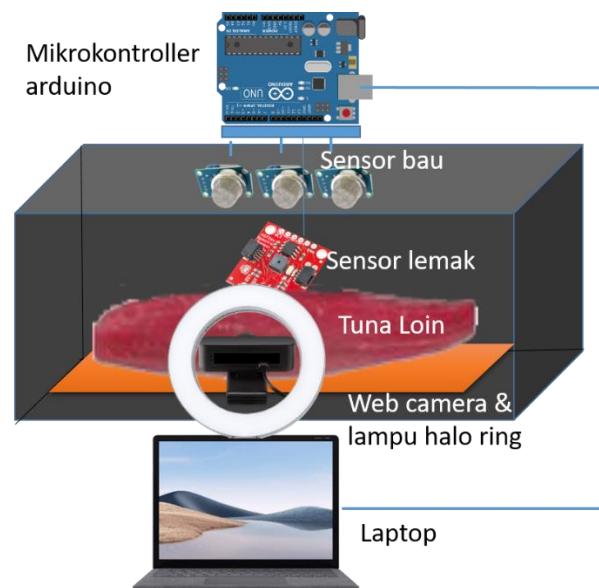
Pembangunan model penentuan kualitas *grade* tuna loin dibagi menjadi 3 tahap yaitu:

- Tahap Akuisisi Data
- Tahap Pelatihan
- Tahap Pengujian

### 4.2.2 Tahap Akuisisi Data

Untuk melakukan penentuan kualitas *grade* tuna loin, maka dirancang alat yang dapat mengakuisisi fitur pada daging tuna loin, fitur yang mempengaruhi dalam penentuan kualitas *grade* tuna loin. Alat yang dibuat direncanakan berupa kotak yang terbuat dari bahan akrilik yang aman dari kontaminasi makanan (*food grade*), dengan warna *background* hitam agar akuisisi citra dari *web camera* di sisi depan memperoleh citra warna dan teksur yang jelas. Dimensi dari kotak yaitu dengan panjang 100 cm, lebar 30 cm dan tinggi 20 cm, dengan pertimbangan rata-rata ukuran loin paling besar dengan panjang 75–80 cm, lebar 18–20 cm dan tinggi 10-12 cm. Untuk sensor bau diletakkan pada bagian atas dari kotak dengan jarak sensor dengan obyek berkisar antara 5 sampai 10 cm. Hal ini berdasarkan penelitian sebelumnya, sensor gas memiliki sensitivitas mengenali obyek dengan jarak optimum 10 cm

(Esculenta & Faqih, 2019). Sensor lemak/minyak direncanakan diletakkan pada sisi berseberangan dengan sisi *web camera*, dengan jarak sensor lemak dengan obyek pada kisaran jarak 3 cm sampai 5 cm. Adapun gambar rancangan alat penentuan kualitas tuna loin ditunjukkan pada Gambar 4.2



Gambar 4.2 Rancangan Alat Penentuan Kualitas Daging Tuna Loin

Rancangan alat menggunakan sensor gas MQ-4, MQ-135 dan MQ-136. Akuisi profil bau tuna loin mempertimbangkan adanya residu bau setelah dilakukan akuisisi terhadap daging loin sebelumnya. Berdasarkan karakteristik sensor gas yang digunakan, sensor memerlukan beberapa detik untuk identifikasi profil bau dan pemulihan ke kondisi semula yang disebut sebagai waktu respons dan waktu pemulihan. Waktu respons merupakan waktu yang dibutuhkan sensor untuk mencapai 90% respon saat terpapar gas dari obyek yang diakuisisi. Sensor juga memiliki waktu pemulihan untuk melakukan akuisisi terhadap obyek berikutnya. Waktu pemulihan didefinisikan sebagai waktu yang dibutuhkan sensor untuk kembali ke dalam kondisi 90% (dari kondisi awal) setelah mengeluarkan gas sebelumnya. Berdasarkan data spesifikasi produk sensor, sensor MQ-4 memiliki waktu respons  $\leq 10$  detik, dan waktu pemulihan  $\leq 30$  detik (Rees52, 2021). Sedangkan sensor MQ-136 memiliki waktu respons yang cepat  $< 1$  detik dengan waktu pemanasan (*warming up*) antara 3 sampai

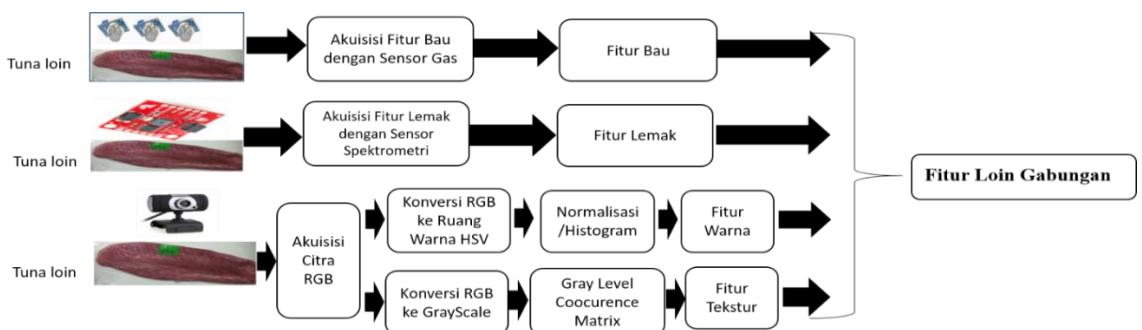
5 menit, dan waktu pemulihan di bawah 30 detik (Amazon.co.uk, 1996). Untuk sensor MQ-137 memiliki waktu respons di bawah 1 detik dengan waktu pemanasan (*warming up*) sekitar 30 sampai 50 menit, dan waktu pemulihan sekitar di bawah 30 detik (Daraz, 2022). Untuk sensor *spectroscopy*, memiliki waktu untuk mencapai kondisi start berikutnya yang disebut *setup time for a start condition (tSU; STA)* selama 0.6  $\mu$ s. Sedangkan waktu minimum yang diperlukan untuk mencapai kondisi stabil sebelum akuisisi obyek (*data setup time*) adalah 250 ns (Afzal, n.d.).

Sehubungan dengan pengaruh gas residu pada saat akuisisi bau daging tuna, akuisisi daging loin selanjutnya diberikan jeda sekitar 15 detik ( $\leq$  30 detik) untuk akuisisi daging tuna berikutnya dan memasang dan menyalakan kipas (*fan*) untuk menghilangkan gas residual dengan cepat setelah selesai melakukan akuisisi fitur bau (Mazwani Abdullah et al., 2022). Tabel 4.1 menunjukkan waktu respons dan waktu pemulihan masing-masing sensor.

Tabel 4.1. Waktu Respons dan Waktu Pemulihan Sensor  
Sumber: (Rees52, 2021) (Amazon.co.uk, 1996) (Afzal, n.d.)

<i>Waktu Sensor</i>	Waktu Respons	Waktu Pemulihan
MQ-4	$\leq$ 10 detik	$\leq$ 30 detik
MQ-136	$\leq$ 1 detik	$\leq$ 30 detik
MQ-137	$\leq$ 1 detik	$\leq$ 30 detik
AS-7263	$\leq$ 0.6 $\mu$ s	$\leq$ 250 ns

Dari semua data sampel yang diakuisisi, sebagian sampel digunakan untuk data pelatihan dan sebagian sampel digunakan untuk data pengujian. Tahapan akuisisi data ditunjukkan pada Gambar 4.3.

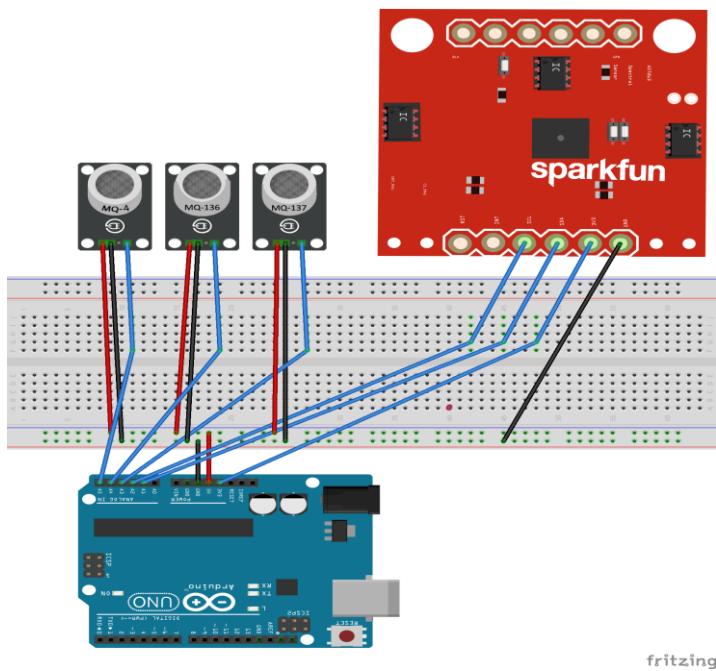


Gambar 4.3 Skema Diagram Akuisisi Data

Akuisisi citra dilakukan menggunakan *web camera*, dan citra yang diperoleh selanjutnya di *pre-processing* untuk mendapatkan fitur warna dan fitur tekstur. Proses ekstraksi fitur warna, dilakukan dengan citra yang diperoleh selanjutnya dikonversi dari ruang warna RGB ke ruang warna HSV, selanjutnya dinormalisasi histogram sehingga diperoleh fitur warna citra. Selanjutnya citra yang diperoleh, dilakukan proses ekstraksi fitur tekstur, melalui konversi ruang warna RGB ke *grayscale*, dan ekstraksi fitur tekstur menggunakan algoritma *grayscale co-occurrence matrix*. Fitur bau, fitur lemak, fitur warna dan fitur tekstur digabungkan untuk selanjutnya dilatih menggunakan algoritma *deep learning neural network*.

#### 4.2.3 Skematik Diagram Sensor

Adapun skematik diagram sensor ditunjukkan pada Gambar 4.4



Gambar 4.4 Skematik Diagram Sensor

Gambar 4.4 menunjukkan skematik diagram sensor yang dihubungkan ke mikrokontroler Arduino (didesain dengan *software Fritzing*). Skematik diagram terdiri dari 3 sensor gas dan 1 sensor *spectrometry*. Catu daya sensor disediakan melalui pin VCC dan pin VCC setiap sensor gas dihubungan ke pin 5V dari mikrokontroler

*Arduino Uno*. Pin GND setiap sensor gas dihubungkan ke pin GND mikrokontroler. Pin data A0 dari sensor gas dihubungkan ke pin data analog mikrokontroler Arduino berturut-turut pada A5, A4, A3.

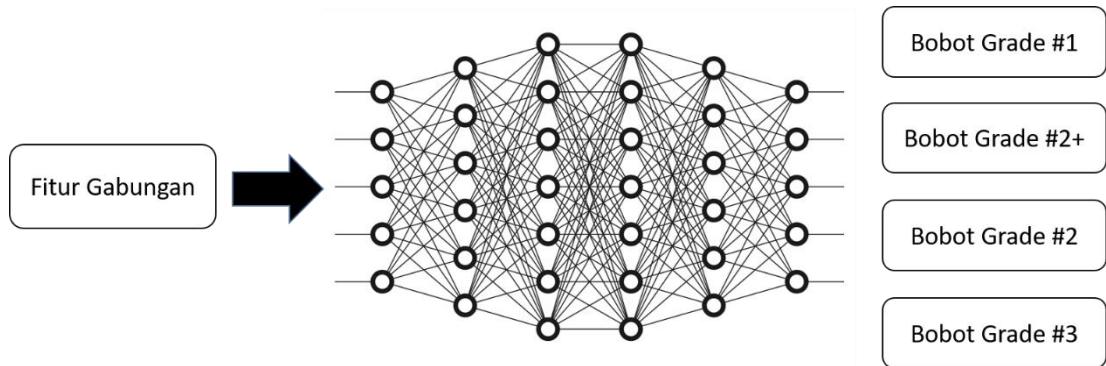
Pada sensor *spectrometry* memiliki pin untuk komunikasi melalui protokol I<sup>2</sup>C (*Inter Integrated Circuit*) sebagai standar komunikasi serial dua arah menggunakan dua saluran yang dirancang khusus untuk mengirim maupun menerima data. *Inter Integrated Circuit* mempermudah komunikasi antar komponen pada rangkaian karena I<sup>2</sup>C hanya membutuhkan dua jalur kabel yaitu *serial clock* (SCL) dan *serial data* (SDA). SCL merupakan jalur *clock* yang digunakan untuk mensinkronkan data transfer antara *master* dan *slave* dalam I<sup>2</sup>C bus sedangkan SDA merupakan jalur komunikasi data dua arah. SDA dan SCL dihubungkan ke seluruh komponen dalam bus I<sup>2</sup>C. Selain itu ada jalur ketiga yaitu *ground* serta jalur VCC sebagai catu daya untuk menghidupkan perangkat/komponen. Pin SCL dihubungan ke pin data analog A2 dan pin SDA dihubungkan ke pin data analog A1. Catu daya sensor disediakan melalui pin 3V3, pin 3V3 dari mikrokontroler dihubungkan ke pin 3V3 dari sensor *spectrometry*. Pin GND dari mikrokontroler dihubungkan ke pin GND dari sensor *spectrometry*.

#### 4.2.4 Kalibrasi Sensor Gas

Nilai yang ditunjukkan dari sensor gas MQ-4, MQ-136 dan MQ-137 merupakan nilai tegangan sensor yang bereaksi terhadap gas yang dideteksi dari obyek. Selanjutnya nilai yang diakuisisi dari sensor gas tersebut dikalibrasi berdasarkan *datasheet* sensor grafik karakteristik sensitivitas dari masing-masing sensor untuk menghitung kadar ppm dari gas. Hasil pengukuran kadar ppm sensor MQ-4 diverifikasi dengan membandingkannya dengan hasil pengukuran kadar ppm gas *methane* dari alat MESTEK CDGA02A. Hasil pengukuran kadar ppm gas *hydrogen sulfida* dari sensor gas MQ-136, diverifikasi dengan membandingkannya dengan hasil pengukuran dari alat Wintact WT8822. Hasil pengukuran kadar ppm gas amonia dari sensor gas MQ-137 diverifikasi dengan membandingkannya dengan hasil pengukuran kadar ppm dengan menggunakan kertas tes Hydron AM-40 *Ammonia Test Paper*.

#### 4.2.5 Tahap Pelatihan Fitur Loin

Skema diagram proses pelatihan fitur input ditunjukkan pada Gambar 4.5

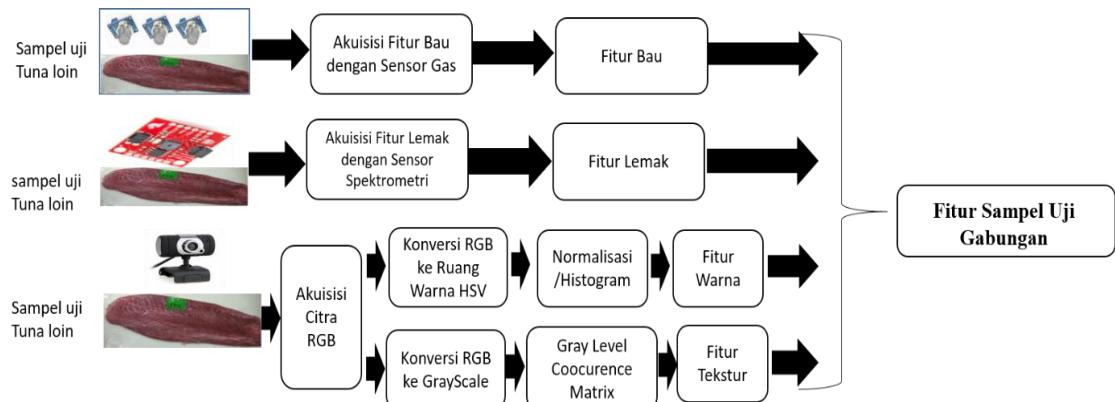


Gambar 4.5 Skema Diagram Proses Pelatihan Fitur Input

Proses pelatihan fitur input menggunakan *deep learning neural network*. Hasil pelatihan menghasilkan bobot pelatihan setiap kelas *grade* yaitu bobot *grade* #1, bobot *grade* #2+, bobot *grade* #2, dan bobot *grade* #3. Selain itu klasifikasi kelas *grade* menggunakan algoritma *k-Nearest Neighbor*, dan untuk mengetahui kerja kedua algoritma klasifikasi dibandingkan, untuk mengetahui algoritma terbaik untuk klasifikasi.

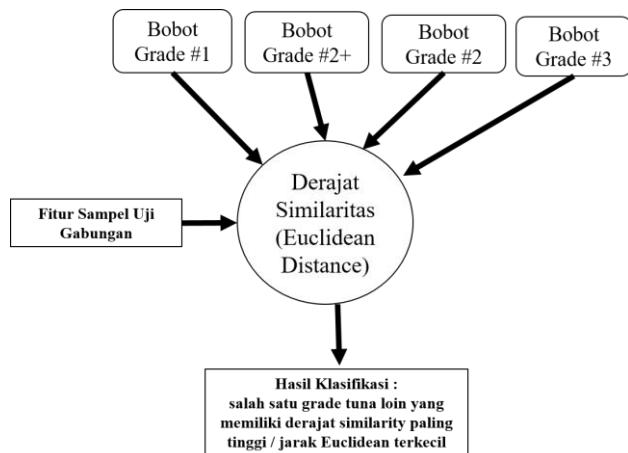
#### 4.2.6 Tahap Pengujian Sampel Loin Uji

Proses pengujian sistem klasifikasi dilakukan dengan mengakuisisi fitur sampel uji tuna loin. Fitur yang diakuisisi adalah fitur bau, fitur lemak, fitur warna dan fitur tekstur. Akuisisi fitur sampel uji memiliki tahapan proses yang sama dengan tahap akuisisi data pelatihan. Semua fitur diatas selanjutnya digabungkan menjadi fitur sampel uji gabungan. Skema diagram proses pengujian ditunjukkan pada Gambar 4.6.



Gambar 4.6 Skema Diagram Akuisisi Data Sampel Uji

Setelah diperoleh fitur sampel uji gabungan, selanjutnya dilakukan proses penentuan/klasifikasi dengan menghitung derajat similaritas fitur sampel uji gabungan dengan empat bobot pelatihan yang diperoleh dari proses pelatihan. Skema diagram penentuan data sampel uji ditunjukkan pada Gambar 4.7.

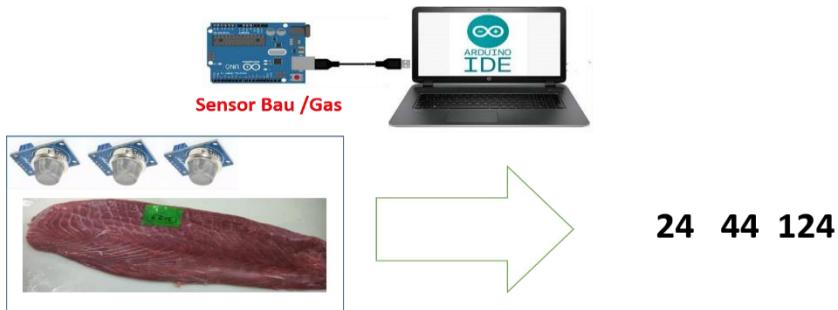


Gambar 4.7 Skema Diagram Penentuan Data Sampel Uji

Penentuan data sampel uji dilakukan menggunakan algoritma derajat similaritas dengan menghitung jarak *euclidean distance* fitur sampel uji dengan masing-masing bobot *grade*, sehingga diperoleh empat nilai yang menggambarkan jarak fitur sampel ke setiap *grade*. Fitur sampel uji dikenali masuk ke dalam salah satu kualitas *grade* tuna loin jika memiliki jarak *euclidean* terpendek, yang berarti karakteristik sampel uji memiliki kemiripan dengan *grade* tersebut.

#### 4.2.7 Deteksi Tingkat Kesegaran Loin Dari Bau Menggunakan Sensor Gas

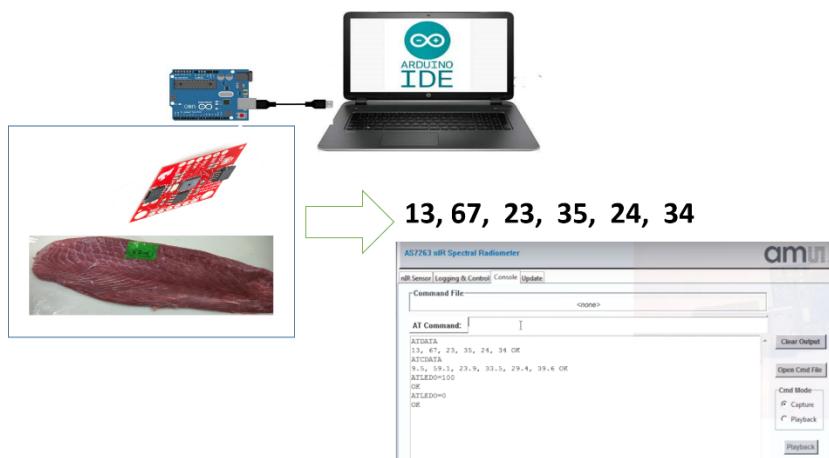
Berdasarkan teori untuk mengenali kualitas *grade* loin, untuk tahap awal dilakukan pengecekan derajat kesegaran ikan/tuna loin dengan cara *sensory* (menggunakan indera manusia, indera perasa, indera bau dan kekenyalan daging tuna). Untuk mengidentifikasi derajat kesegaran ikan melalui identifikasi bau daging tuna. Penelitian ini menggunakan sensor gas MQ-4, MQ-136, MQ-137, dimana sensor ini untuk mendeteksi kandungan gas *methane*, *hydrogen sulfide* dan amoniak pada tuna loin yang mengindikasikan tuna loin dalam kondisi segar, atau tidak segar (Pusdik.kkp.go.id, 2019). Model Proses Akuisisi Fitur Bau ditunjukkan pada Gambar 4.8.



Gambar 4.8. Model Proses Akuisisi Fitur Bau

#### 4.2.8 Deteksi Kandungan Lemak Loin Dengan Sensor Spektrometer

Berdasarkan teori untuk mengenali *grade* loin, salah satu fitur yang disebutkan adalah kandungan lemak/minyak tuna loin (DiGregorio, 2012). Untuk mengidentifikasi kandungan lemak tuna loin, maka digunakan sensor *near infrared*, *SparkFun Spectral Sensor Breakout - AS7263*(Buniyamin et al., 2011). Sensor ini menggunakan gelombang elektromagnetik untuk menentukan komposisi dari obyek yang dideteksi, dengan menggunakan 6 *channel* panjang gelombang yaitu 450nm, 500nm, 550nm, 570nm, 600nm dan 650nm, yang direpresentasikan dalam fitur 6 angka berupa derajat kandungan lemak pada tuna loin (Electronics, n.d.). Model proses akuisisi fitur lemak/minyak ditunjukkan pada Gambar 4.9.



Gambar 4.9. Model Proses Akuisisi Fitur Lemak/Minyak

#### 4.2.9 Akuisisi Citra Loin

Akuisisi citra loin menggunakan *web camera* dengan resolusi 4 megapiksel yang memiliki fitur auto kontras dan menggunakan pencahayaan obyek yang baik untuk mendapatkan kualitas citra loin tetap baik dari efek pencahayaannya stabil dan

tidak berubah ubah. Hal ini bertujuan untuk memperoleh fitur warna yang konstan pada setiap citra tuna loin.

Adapun tahapan ekstraksi citra loin sebagai berikut:

- a. Citra yang sudah diperoleh dari *web camera*, selanjutnya dikonversi ke dalam ruang warna RGB
  - b. Citra dalam ruang warna RGB, dikonversi menghasilkan ruang warna HSV untuk menghasilkan fitur citra warna
  - c. Fitur ruang warna HSV di ekstraksi dan di normalisasi histogram sehingga diperoleh fitur normalisasi citra warna.
  - d. Citra dalam ruang warna RGB, dikonversi ke *grayscale* yang selanjutnya menghasilkan fitur tekstur dengan algoritma *gray level co-occurrence matrix*

#### 4.2.10 Konversi Citra Warna RGB ke HSV

Citra yang diperoleh selanjutnya di ekstraksi dari ruang warna RGB ke ruang warna HSV. Konversi ke ruang warna HSV mengikuti persamaan berikut(OpenCV, 2021) :

$$r = \frac{R}{R+G+B}, \quad g = \frac{G}{R+G+B}, \quad b = \frac{B}{R+G+B} \quad \dots \quad (10)$$

$$S = \begin{cases} 0, & \text{if } V = 0 \\ 1 - \frac{\min(r, g, b)}{n}, & \text{if } V > 0 \end{cases} \dots \quad (12)$$

$$H = \begin{cases} 0 & \text{jika } S = 0 \\ \frac{60*(g-b)}{S*V} & \text{jika } V = r \\ 60 * \left[ 2 + \frac{b-r}{S*V} \right], & \text{jika } V = g \\ 60 * \left[ 4 + \frac{r-g}{S*V} \right], & \text{jika } V = b \end{cases} \quad (13)$$

Perhitungan pencarian nilai HSV diatas secara keseluruhan dilakukan dengan rumus dan cara yang sama, sehingga di peroleh nilai HSV keseluruhan dapat dilihat dalam bentuk matrik H, matrik S dan matrik V sebagai berikut:

#### 4.2.11 Konversi Citra Loin Dari RGB ke *Grayscale*

Nilai RGB akan dikonversi ke dalam *grayscale* dengan mengubah nilai setiap piksel RGB kedalam nilai derajat aras keabuan. Perhitungan konversi *grayscale* dengan rumus:

dengan

**Gx = nilai intensitas *grayscale***

R = nilai intensitas piksel warna merah

$G = \text{nilai intensitas piksel warna hijau}$

$B = \text{nilai intensitas piksel warna biru}$

Perhitungan dilakukan dengan cara dan persamaan yang sama untuk setiap piksel RGB

#### **4.2.12 Ekstraksi Fitur Tekstur Dengan *Gray Level Co-occurrence Matrix* (*GLCM*)**

Ekstraksi fitur tekstur dilakukan dengan membentuk matriks *co-occurrence* berdasarkan matrik citra RGB yang telah dikonversi menjadi matriks *grayscale*. Matrik *co-occurrence* dibentuk dengan cara mencari hubungan spasial dari matrik *grayscale* kemudian dituliskan kedalam ruang area kerja matrik. Pencarian hubungan spasial dilakukan pada matrik *grayscale* kemudian dituliskan pada ruang area kerja matrik.

- a. Citra dengan matrix di bawah ini di konversi menjadi GLCM

Diberikan contoh citra input dengan matrix  $4 \times 4$  seperti Gambar 4.10

0	2	1	0
1	1	0	1
0	1	0	2
0	2	3	0

Gambar 4.10 Contoh Matriks Citra Input

Mendefinisikan *framework matrix* bernilai 0, untuk *gray tone* bernilai 0 sampai 3, sehingga perlu dibuat *framework matrix* dengan size 4x4. Tiap posisi pada

framework matrix merupakan kombinasi nilai pixel pada matrix input 3x3, ditunjukkan pada Gambar 4.11.

	0	1	2	3
0	0,0	0,1	0,2	0,3
1	1,0	1,1	1,2	1,3
2	2,0	2,1	2,2	2,3
3	3,0	3,1	3,2	3,3

Gambar 4.11 Contoh Kombinasi Nilai Piksel Matrix 3 x 3

Hasil konversi menjadi matriks GLCM dengan sudut  $0^0$  pada Gambar 4.12

	0	1	2	3
0	0	2	3	0
1	3	1	0	0
2	0	1	0	1
3	1	0	0	0

Gambar 4.12 Contoh Matrix GLCM Sudut  $0^0$

b. Matrix GLCM di jumlahkan dengan matriks GLCM transpose, pada Gambar 4.13

<table border="1" style="border-collapse: collapse; text-align: center;"> <tr><td>0</td><td>2</td><td>3</td><td>0</td></tr> <tr><td>3</td><td>1</td><td>0</td><td>0</td></tr> <tr><td>0</td><td>1</td><td>0</td><td>1</td></tr> <tr><td>1</td><td>0</td><td>0</td><td>0</td></tr> </table>	0	2	3	0	3	1	0	0	0	1	0	1	1	0	0	0	+	<table border="1" style="border-collapse: collapse; text-align: center;"> <tr><td>0</td><td>3</td><td>0</td><td>1</td></tr> <tr><td>2</td><td>1</td><td>1</td><td>0</td></tr> <tr><td>3</td><td>0</td><td>0</td><td>0</td></tr> <tr><td>0</td><td>0</td><td>1</td><td>0</td></tr> </table>	0	3	0	1	2	1	1	0	3	0	0	0	0	0	1	0
0	2	3	0																															
3	1	0	0																															
0	1	0	1																															
1	0	0	0																															
0	3	0	1																															
2	1	1	0																															
3	0	0	0																															
0	0	1	0																															

Gambar 4.13 Contoh Penjumlahan Matrix GLCM dengan GLCM Transpose Sudut  $0^0$

Hasil matrix GLCM simetris sudut  $0^0$

<table border="1" style="border-collapse: collapse; text-align: center;"> <tr><td>0</td><td>5</td><td>3</td><td>1</td></tr> <tr><td>5</td><td>2</td><td>1</td><td>0</td></tr> <tr><td>3</td><td>1</td><td>0</td><td>1</td></tr> <tr><td>1</td><td>0</td><td>1</td><td>0</td></tr> </table>	0	5	3	1	5	2	1	0	3	1	0	1	1	0	1	0
0	5	3	1													
5	2	1	0													
3	1	0	1													
1	0	1	0													

Gambar 4.14 Contoh Hasil Penjumlahan Matrix GLCM dan Transpose Sudut  $0^0$

Matrix GLCM selanjutnya di normalisasi dengan membagi setiap intensitas citra dengan total nilai intensitas keseluruhan, matriks normalisasi digunakan untuk mendapatkan ekstraksi ciri. Matrix GLCM 4x4 dengan sudut  $0^0$  setelah di normalisasi seperti pada Gambar 4.15

0	0.208	0.125	0.0416
0.208	0.083	0.041	0
0.125	0.0416	0	0.0416
0.0416	0	0.0416	0

Gambar 4.15 Contoh Hasil Normalisasi Matrix GLCM

Metode GLCM menghasilkan lima fitur dari citra digital dari tiap sudut ketetanggaan pikselnya. Lima fitur tersebut yaitu *angular second moment* (ASM), kontras, *inverse different moment* (IDM), entropi dan korelasi.

- c. ASM merupakan ukuran homogenitas citra. ASM memiliki nilai tinggi ketika citra memiliki homogenitas yang baik atau nilai piksel yang hampir serupa.

- d. Kontras menunjukkan ukuran intensitas aras keabuan antara piksel dengan piksel lainnya dengan lokasi relatif. Kontras memiliki batas nilai dari 0 hingga pangkat 2 dari panjang matriks GLCM simetris. Pada citra dengan elemen piksel yang bernilai sama secara keseluruhan maka nilai kontras = 0.

- e. IDM menunjukkan homogenitas lokal. IDM berkaitan dengan kontras. Bobot IDM berkebalikan dengan kontras

- f. Entropi menunjukkan ketidakteraturan aras keabuan dalam suatu citra. Nilai entropi akan semakin tinggi jika nilai elemen piksel citra semakin acak

- g. Korelasi mengukur ketergantungan linier dari aras keabuan dalam ketetanggaan piksel citra.

dengan

#### **4.2.13 Pelatihan Fitur Menggunakan Algoritma *Deep Learning Convolutional Neural Network***

Algoritma *Convolutional Neural Network* (CNN) merupakan pengembangan dari *Multilayer Perceptron* (MLP) yang didesain untuk mengolah data dua dimensi. CNN termasuk dalam jenis *Deep Neural Network* karena kedalaman jaringan yang tinggi dan banyak diaplikasikan pada data citra. CNN pertama kali dikembangkan dengan nama *NeoCognitron* oleh Kunihiko Fukushima, seorang peneliti dari NHK *Broadcasting Science Research Laboratories*, Tokyo, Jepang. Konsep tersebut kemudian dimatangkan oleh Yann LeChun, seorang peneliti dari AT&T Bell Laboratories New Jersey, USA. Model CNN dengan nama LeNet berhasil diterapkan oleh LeChun pada penelitiannya mengenai penentuan angka dan tulisan tangan. Berdasarkan arsitektur LeNet5, terdapat empat macam *layer* utama pada sebuah CNN yaitu

### a) Convolution Layer

*Convolution layer* melakukan operasi konvolusi pada output dari *layer* sebelumnya. Konvolusi merupakan proses mengaplikasikan sebuah filter secara berulang terhadap input yang diterima. Filter yang diberikan berupa kernel yang bergerak dari sudut kiri atas matriks input hingga mencapai sudut kanan bawah matriks input. Proses konvolusi digambarkan seperti pada Gambar 4.16.

$$\begin{array}{|c|c|c|c|c|c|} \hline
 3 & 0 & 1 & 2 & 7 & 4 \\ \hline
 1 & 5 & 8 & 9 & 3 & 1 \\ \hline
 2 & 7 & 2 & 5 & 1 & 3 \\ \hline
 0 & 1 & 3 & 1 & 7 & 8 \\ \hline
 4 & 2 & 1 & 6 & 2 & 8 \\ \hline
 2 & 4 & 5 & 2 & 3 & 9 \\ \hline
 \end{array}
 \quad *
 \quad
 \begin{array}{|c|c|c|} \hline
 1 & 0 & -1 \\ \hline
 1 & 0 & -1 \\ \hline
 1 & 0 & -1 \\ \hline
 \end{array}
 \quad =
 \quad
 \begin{array}{|c|c|c|c|} \hline
 -5 & -4 & 0 & 8 \\ \hline
 -10 & -2 & -2 & 3 \\ \hline
 0 & -2 & -4 & -7 \\ \hline
 -3 & -2 & -3 & -16 \\ \hline
 \end{array}$$

3 x 3

4 x 4

Gambar 4.16. Contoh Proses Konvolusi  
(Sumber: Kim, 2017)

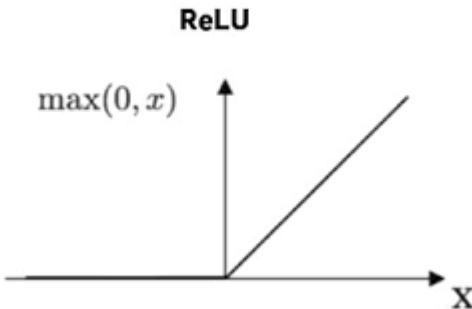
Pada Gambar 4.16 matriks citra input  $6 \times 6$  di konvolusi dengan kernel  $3 \times 3$ . Kernel bergerak dari sudut kiri atas ke kanan bawah. Sehingga hasil konvolusi dari citra tersebut menjadi matriks hasil konvolusi  $4 \times 4$  yang dapat dilihat pada gambar disebelah kanannya. Tujuan dilakukannya konvolusi pada data citra adalah untuk mengekstraksi fitur dari citra input. Konvolusi akan menghasilkan transformasi linear dari data input sesuai informasi spasial pada data. Bobot pada *layer* tersebut menspesifikasikan kernel konvolusi yang digunakan, sehingga kernel konvolusi dapat dilatih berdasarkan input pada *Convolutional Neural Network*. *Output* dari proses konvolusi berupa data tunggal yang digunakan kembali sebagai *input* pada proses konvolusi selanjutnya.

b. *Stride*

*Stride* sebagai parameter yang menentukan berapa jumlah pergeseran filter. Jika nilai *stride* adalah 1, *convolutional kernel* bergeser setiap 1 piksel secara horizontal dari kiri atas ke kanan bawah. Semakin kecil *stride* maka akan semakin detail informasi yang kita dapatkan dari sebuah input, namun membutuhkan komputasi yang lebih jika dibandingkan dengan *stride* yang besar.

c. Fungsi Aktivasi *Rectification Linear Unit (ReLU)*

Fungsi aktivasi berada pada tahap sebelum melakukan *pooling layer* dan setelah melakukan proses konvolusi. Pada tahap ini, nilai hasil konvolusi dikenakan fungsi aktivasi. Fungsi aktivasi yang digunakan adalah ReLU (*Rectification Linear Unit*) dengan sifatnya yang lebih berfungsi dengan baik.

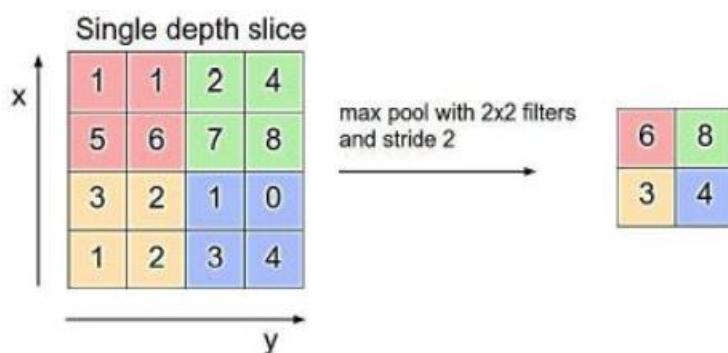


Gambar 4.17. Fungsi Aktivasi *ReLU* (Kim, 2017)

Fungsi yang digunakan untuk aktivasi menggunakan *ReLU* yaitu nilai luaran dari neuron bisa dinyatakan sebagai 0 jika inputnya adalah negatif. Jika nilai input dari fungsi aktivasi adalah positif, maka output dari neuron adalah nilai input aktivasi itu sendiri.

#### e. Pooling Layer

*Pooling layer* melakukan proses subsampling sebagai proses mereduksi ukuran sebuah data citra. Dalam pengolahan citra, subsampling juga bertujuan untuk meningkatkan invariansi posisi dari fitur. *Pooling layer* yang digunakan adalah *max pooling layer* yang membagi *output* dari *convolution layer* menjadi beberapa grid kecil lalu mengambil nilai maksimal dari setiap grid untuk menyusun matriks citra yang telah direduksi seperti yang ditunjukkan pada Gambar 4.18. *Grid* yang berwarna merah, hijau, kuning dan biru merupakan kelompok grid yang akan dipilih nilai maksimumnya. Sehingga hasil dari proses tersebut dapat dilihat pada kumpulan grid disebelah kanannya. Proses tersebut memastikan fitur yang didapatkan akan sama meskipun objek citra mengalami translasi (pergeseran).



Gambar 4.18. Operasi *Max Pooling*  
(Sumber: Kim, 2017)

Menurut Springenberg et al., penggunaan *pooling layer* pada CNN hanya bertujuan untuk mereduksi ukuran citra sehingga dapat dengan mudah digantikan dengan sebuah convolution *layer* dengan stride yang sama dengan *pooling layer* yang bersangkutan.

f. *Fully Connected Layer*

*Layer* tersebut adalah *layer* yang biasanya digunakan dalam penerapan *Multilayer Perceptron* (MLP) dan bertujuan untuk melakukan transformasi pada dimensi data agar data dapat diklasifikasikan secara linear. Setiap neuron pada *convolution layer* perlu ditransformasi menjadi data satu dimensi terlebih dahulu sebelum dapat dimasukkan ke dalam sebuah *fully connected layer*. Karena hal tersebut menyebabkan data kehilangan informasi spasialnya dan tidak reversibel, *fully connected layer* hanya dapat diimplementasikan di akhir jaringan. *Convolutional layer* dengan ukuran kernel 1 x 1 melakukan fungsi yang sama dengan sebuah *fully connected layer* namun dengan tetap mempertahankan karakter spasial dari data. *Fully Connected Layer* melakukan transformasi pada dimensi data agar data dapat diklasifikasikan secara linear.

#### 4.2.14 Pelatihan Fitur Menggunakan Algoritma *k-Nearest Neighbor*

Algoritma *k-Nearest Neighbor* adalah algoritma *supervised learning* dimana hasil dari *instance* yang baru diklasifikasikan berdasarkan mayoritas dari kategori k-tetangga terdekat (Bermúdez et al., 2020). Tujuan dari algoritma ini adalah untuk mengklasifikasikan obyek baru berdasarkan atribut dan sampel training data. Algoritma *k-Nearest Neighbor* menggunakan *Neighborhood Classification* sebagai nilai prediksi dari nilai *instance* yang baru. Algoritma *k-Nearest Neighbors* sebagai berikut (Ismail, 2018):

- a. Menentukan jumlah tetangga (titik data) terdekat yg akan kita perhitungkan (k)
- b. Menghitung jarak setiap tetangga (titik data) terhadap titik data yang baru tersebut, lalu urutkan hasilnya berdasarkan jarak, mulai dari yang terkecil ke yang terbesar.
- c. Mengambil jumlah k tetangga yang paling dekat, lalu dilihat masing-masing dari tetangga tersebut apakah termasuk kedalam wilayah kelas yang ditentukan. Jika dari sejumlah tetangga tersebut terdapat dominan titik data termasuk ke dalam sebuah kelas, maka titik data baru masuk ke dalam kelas tersebut.

- d. Dalam menentukan nilai  $k$ , bila jumlah klasifikasi genap maka sebaiknya menggunakan nilai  $k$  ganjil, dan begitu pula sebaliknya bila jumlah klasifikasi ganjil maka sebaiknya menggunakan nilai  $k$  genap.

#### 4.2.15 Pengujian Model Klasifikasi

*Confusion matrix* adalah salah satu metode yang digunakan untuk mengevaluasi metode-metode klasifikasi. *Confusion matrix* juga sering disebut *error matrix*. Pada dasarnya *confusion matrix* memberikan informasi perbandingan hasil klasifikasi yang dilakukan oleh sistem (model) dengan hasil klasifikasi sebenarnya. *Confusion matrix* berbentuk tabel matriks yang menggambarkan kinerja model klasifikasi pada serangkaian data uji yang nilai sebenarnya diketahui. Tabel 4.2 menunjukkan *confusion matrix* dengan 4 kombinasi nilai prediksi dan nilai aktual yang berbeda. Terdapat 4 istilah sebagai representasi hasil proses klasifikasi *confusion matrix* yaitu True Positive (TP), True Negative (TN), False Positive (FP) dan False Negative (FN).

Tabel 4.2. Kelas Prediksi *Confusion Matrix*(Kim, 2017)

		Kelas Prediksi	
		Positif	Negatif
Kelas	Positif	TP	FN
	Aktual	Negatif	FP

Agar lebih mudah memahaminya, digunakan contoh kasus sederhana untuk memprediksi seorang pasien menderita kanker atau tidak.

a. *True Positive* (TP)

Merupakan data positif yang diprediksi benar, data yang diklasifikasi dengan tepat sebagai keluaran positif. Contohnya, pasien menderita kanker (*class 1*) dan dari model yang dibuat memprediksi pasien tersebut menderita kanker (*class 1*).

b. *True Negative* (TN)

Merupakan data negatif yang diprediksi benar, data yang di klasifikasi dengan tepat sebagai keluaran negatif. Contohnya, pasien tidak menderita kanker (*class 2*) dan dari model yang dibuat memprediksi pasien tersebut tidak menderita kanker (*class 2*).

### c. *False Positive* (FP) — Type I Error

Merupakan data negatif namun diprediksi sebagai data positif Contohnya, pasien tidak menderita kanker (*class 2*) tetapi dari model yang telah memprediksi pasien tersebut menderita kanker (*class 1*).

d. *False Negative (FN) — Type II Error*

Merupakan data positif namun diprediksi sebagai data negative (data yang diklasifikasi dengan kurang tepat). Contohnya, pasien menderita kanker (*class 1*) tetapi dari model yang dibuat memprediksi pasien tersebut tidak menderita kanker (*class 2*).

Manfaat *confusion matrix* adalah algoritma ini akan memberi tahu seberapa baik model yang kita rancang dan *confusion matrix* juga memberikan informasi tentang TP, FP, TN, dan FN. Hal ini sangat berguna karena hasil dari klasifikasi umumnya tidak dapat diekspresikan dengan baik dalam satu angka saja. Dengan contoh yang sama untuk memprediksi kanker, dapat diprediksi siapa yang akan mati karena kanker tahun ini berdasarkan perilaku seperti merokok dari seluruh populasi. Pada tahun tertentu, hanya 1% populasi yang mati karena kanker. Algoritma klasifikasi naif hanya akan memprediksi tidak ada yang mati karena kanker. Dengan *confusion matrix* memungkinkan untuk melihat dengan cepat, siapa yang akan diprediksi mati karena penyakit kanker, proporsi berapa banyak yang mati dan berapa banyak yang tidak. Berikut adalah beberapa manfaat dari *confusion matrix* sebagai berikut:

- a. Menunjukkan bagaimana model ketika membuat prediksi.
  - b. Tidak hanya memberi informasi tentang kesalahan yang dibuat oleh model tetapi juga jenis kesalahan yang dibuat.
  - c. Setiap kolom dari *confusion matrix* merepresentasikan *instance* dari kelas prediksi.
  - d. Setiap baris dari *confusion matrix* mewakili *instance* dari kelas aktual.

#### 4.2.16 Akurasi Klasifikasi Model CNN

Akurasi didefinisikan sebagai persentase dari data uji yang benar (baik benar positif dan benar negatif) diantara jumlah total sampel uji. Akurasi dapat dinyatakan dalam persamaan 28 (Novaković et al., 2017).

*Precision* merupakan rasio prediksi benar positif dibandingkan dengan keseluruhan hasil yang di prediksi positif. Untuk menghitung nilai *precision* digunakan persamaan 29

*Recall* merupakan perbandingan prediksi jumlah benar positif dibandingkan dengan keseluruhan data yang benar positif. Untuk menghitung nilai recall digunakan persamaan 30.

*Specificity* merupakan kebenaran memprediksi negatif dibandingkan dengan keseluruhan data negatif. *Specificity* dirumuskan dalam persamaan 31.

*F1 Score* merupakan perbandingan rata-rata *presisi* dan *recall* yang dibobotkan, dirumuskan seperti persamaan 32.

#### 4.2.17 Visualisasi Data

Visualisasi data sebagai model bertujuan untuk menyajikan informasi mengenai hasil penelitian. Visualisasi data dapat diimplementasikan menggunakan bahasa pemrograman *python* dengan *library* keras, atau dapat juga menggunakan bahasa pemrograman *web*. Data visualisasi pada penelitian ini menampilkan grafik korelasi bau, warna, tekstur dan kandungan lemak tuna loin berpengaruh pada *grade* tuna loin.

#### 4.17 Lokasi Dan Waktu Penelitian

Data penelitian akan diambil pada salah satu perusahaan pengolahan ikan tuna di daerah Maluku. Pemilihan lokasi ini karena perusahaan pengolahan ikan ini mengolah ikan tuna yang berasal dari Maluku, Maluku Utara dengan *grade* yang

baik(Firdaus, 2019) (Simanjuntak et al., 2019)(C. J. Lintang et al., 2012). Selain itu perusahaan pengolahan ikan ini menghasilkan produk perikanan yang di ekspor ke mancanegara seperti Amerika Serikat, dan Vietnam. Penelitian dilakukan untuk membangun model sistem berbasis *neural network* dalam penentuan *grade* tuna loin dengan melakukan pemrograman sistem secara mandiri. Waktu penelitian dilakukan selama kurun waktu 3 tahun dengan tahapan kegiatan sesuai dengan peta penelitian pada Gambar 4.1.

#### **4.18 Ruang Lingkup Penelitian**

Penelitian memiliki keterbatasan, sehingga perlu mendefinisikan ruang lingkup penelitian. Berhubung penelitian tersebut memiliki berbagai keterbatasan seperti keterbatasan waktu, biaya, tenaga dan agar penelitian dapat dilakukan secara lebih mendalam, maka diperlukan ruang lingkup penelitian. Adapun ruang lingkup penelitian sebagai berikut:

- a) Produk yang diteliti adalah produk loin tuna dari spesies sirip kuning (*yellowfin tuna*) yang ditangkap di wilayah perairan Maluku dan Maluku Utara. Hal ini disebabkan ikan tuna sirip kuning tersebar di beberapa wilayah perairan tersebut (Firdaus, 2019) (Simanjuntak et al., 2019) (C. J. Lintang et al., 2012)
- b) Penentuan *grade* tuna loin berdasarkan 4 parameter yaitu kesegaran, warna, tekstur dan kandungan lemak tuna loin(DiGregorio, 2012)(Gourmets, 2021).
- c) Referensi *grading* tuna loin pada proses pelatihan, ditentukan dari hasil grading operator *grader* (memiliki sertifikat *grader*).
- d) Instrumen penelitian untuk mendeteksi kesegaran ikan tuna menggunakan sensor gas MQ-4, MQ-136, MQ-137 untuk mendeteksi gas *methane*, *hydrogen sulfida* dan bau amoniak (ShowRange, n.d.), yang dirangkai dengan Arduinio Uno ATMega328P. Sensor gas ini dipilih berdasarkan fungsinya untuk mengenali level bau *amoniak* dan gas *methan*, dimana tingkat kesegaran ikan terkait dengan kandungan *amoniak* dan gas *methan*(Pusdik.kkp.go.id, 2019).
- f) Penelitian ini menggunakan instrumen penelitian dengan *web camera* digital CAMTECH CT50 1440P 2K 4MP untuk mendapatkan citra tuna loin dengan kualitas baik.

- e) Penelitian ini mengenali grade tuna loin yang dibagi menjadi 4 grade yaitu grade #1, grade #2+, grade #2, grade #3, berdasarkan fitur bau, warna, tekstur dan kandungan lemak.

## **4.5 Penentuan Sumber Data Penelitian**

### **4.5.1 Jenis Sumber Data**

Dalam penelitian ini, sumber data berasal dari ikan tuna yang diolah di perusahaan pengolahan ikan tuna di Maluku. Sumber datanya berasal dari produk tuna loin yang dihasilkan dari perusahaan pengolahan ikan tersebut. Perusahaan pengolahan ikan ini dipilih sebagai sumber data karena perusahaan pengolahan ikan ini mengolah ikan tuna yang berasal dari Maluku, dan Maluku Utara, yang diketahui memiliki *grade* yang baik(Firdaus, 2019). Selain itu perusahaan pengolahan ikan ini menghasilkan produk perikanan yang di eksport ke mancanegara seperti Amerika Serikat, Vietnam dan Eropa (Firdaus, 2019), sehingga di pandang layak sebagai pusat penelitian. Jenis data yang dikumpulkan dalam penelitian ini berupa data fitur profil bau yang ternormalisasi, data fitur kandungan lemak pada loin yang ternormalisasi, fitur citra warna ternormalisasi dan fitur tekstur. Karena terdapat proses normalisasi pada data fitur tersebut, maka jenis data fitur ini sebagai jenis data rasio, agar menghasilkan data yang terdistribusi normal.

### **4.5.2 Populasi Dan Sampel Data Penelitian**

Menurut Corper, Donald, R; Schindler. Pamela S; 2003 menyatakan “*Population is the total collection of element about which we wish to make some inference. A population element is the subject on which the measurement is being taken*”. Populasi sebagai keseluruhan elemen yang akan dijadikan wilayah generalisasi yang terdiri atas obyek atau subyek yang akan diukur merupakan unit yang diteliti dengan kuantitas dan karakteristik tertentu untuk dipelajari dan dapat ditarik kesimpulan(Sugiyono, 2018).

Berdasarkan sumber data yang digunakan, maka yang dimaksud populasi pada penelitian ini yaitu keseluruhan fitur nilai sensor gas, fitur nilai sensor spektrometri, fitur citra warna dan tekstur loin yang diakuisisi menggunakan *web camera* digital CAMTECH CT50 1440P. Setiap loin tuna menyediakan data fitur nilai sensor gas,

sensor spektrometri, fitur citra loin. Data fitur yang dikumpulkan tersebut diakusisi dari setiap grade tuna loin (grade #1, #2+, #2, #3), dan diberikan identitas grade selanjutnya fitur nilai sensor gas dan nilai sensor spektrometri disimpan dalam database, sedangkan fitur citra loin disimpan dalam folder yang berisi identitas *grade*.

Dalam penelitian kuantitatif, sampel adalah sebagian dari jumlah dan karakteristik yang dimiliki populasi tersebut (Djarwanto, 1994:43)(Sugiyono, 2018:146). Jika populasi besar dan peneliti tidak mungkin mempelajari semua populasi, misalnya karena keterbatasan dana, waktu dan tenaga, maka peneliti dapat menggunakan sampel yang diambil dari populasi tersebut. Pengambilan sampel untuk penelitian kuantitatif umumnya dilakukan secara *random*, sehingga anggota populasi memiliki peluang yang sama untuk dipilih menjadi anggota sampel(Hidayat, 2017). Roscoe dalam bukunya ***Research Methods for Business*** (1982:253) memberikan saran mengenai ukuran sampel penelitian bahwa:

- a. Ukuran sampel yang layak dalam penelitian antara 30 sampai 500 sampel.
- b. Bila sampel dibagi dalam kategori (kelas) maka jumlah anggota sampel setiap kategori minimal 30 sampel.
- c. Bila dalam penelitian akan melakukan analisis multivariate (korelasi atau regresi ganda), maka jumlah anggota sampel minimal sepuluh kali dari jumlah variabel yang diteliti. Misalnya jumlah variabel yang diteliti ada 4 variabel, maka jumlah sampel minimal adalah 40 sampel setiap kategori.

Berdasarkan (Roscoe, 1982) mengingat keterbatasan waktu penelitian, maka penelitian ini akan mengambil sampel pada setiap kelas sejumlah 40 sampel dari setiap grade tuna loin (*grade* #1, #2+, #2, #3). Pada penelitian ini, populasi memiliki anggota/unsur yang tidak homogen dan berstrata proporsional, sehingga teknik pengambilan sampel yang sesuai adalah *probability sampling* dengan teknik *proportionate stratified random sampling*.(Sugiyono, 2018).

#### **4.5.3 Teknik Pengumpulan Data**

Pengumpulan sampel data penelitian ini menggunakan teknik observasi yaitu mengamati dan mengakuisisi data sampel menggunakan sensor gas, sensor spektrometri, data citra tuna loin untuk diperoleh fitur warna dan fitur teksturnya. Adapun teknik pengumpulan data sebagai berikut:

- a. Setiap tuna loin dimasukkan ke dalam wadah kotak yang telah dirangkai sensor dan diukur dengan sensor gas untuk mendapatkan level kesegaran dengan mendeteksi bau amoniak, *methana* dan asam sulfat sebagai fitur bau.
- b. Saat selesai akuisisi tuna loin yang pertama, untuk akuisisi berikutnya diberikan jeda waktu sekitar 15 detik untuk menghilangkan residu bau loin sebelumnya dan sebagai waktu pemulihan sensor ke kondisi semula. Untuk mempercepat waktu pemulihan, dipasang dan dinyalakan kipas untuk menghilangkan residu bau dari akuisisi sebelumnya.
- c. Selanjutnya setiap tuna loin pada wadah tersebut, di ukur kandungan lemaknya dengan menggunakan sensor spektrometer. Fitur yang diperoleh berupa deretan 6 angka yang menunjukkan hasil pengukuran sensor spektrometer.
- d. Pengambilan citra/gambar tuna loin menggunakan kamera digital untuk mendapatkan citra loin yang akan di *pre-processing* untuk mendapatkan fitur citra warna dan fitur tekstur.
- e. Pengumpulan sampel data akan dilaksanakan kurang lebih sekitar 2 bulan pada salah satu perusahaan pengolahan ikan tuna di Maluku, dengan asumsi perkiraan kurun waktu selama 2 bulan, akuisisi data dapat dilakukan secara keseluruhan dengan baik.

#### 4.6 Variabel Penelitian

Variabel merupakan atribut dari obyek penelitian yang memiliki variasi antara satu obyek dengan obyek lainnya (Hatch dan Farhady, 1981). Variabel penelitian merupakan segala sesuatu sebagai atribut obyek penelitian yang ditetapkan oleh peneliti untuk dipelajari sehingga diperoleh informasi tentang hal tersebut kemudian ditarik kesimpulan(Sugiyono, 2018). Menurut hubungan antara satu variabel dengan variabel lainnya, variabel dibedakan menjadi variabel independen (variabel bebas yang dipengaruhi atau yang menjadi sebab perubahannya atau timbulnya variabel dependen atau terikat), variabel dependen (variabel terikat merupakan variabel yang dipengaruhi atau yang menjadi akibat karena adanya variabel bebas), variabel moderator (variabel yang memperkuat dan memperlemah hubungan antara variabel independen dan dependen), variabel intervening (variabel antara yang terletak diantara variabel dependen dan variabel independen merupakan faktor-faktor yang secara teoritis

mempengaruhi fenomena yang diteliti tetapi tidak dapat diukur dan dimanipulasi), dan variabel kontrol (variabel yang dikendalikan atau dibuat konstan sehingga pengaruh variabel independen terhadap variabel dependen tidak dipengaruhi oleh faktor luar yang tidak diteliti) (Sugiyono, 2018). Penelitian ini menggunakan variabel independen berupa level bau, kandungan lemak, citra warna, dan tekstur dan variabel dependen adalah *grade* tuna loin.

## 4.7 Instrumen Penelitian

### 4.7.1 Alat Penelitian

#### a. Identifikasi Kesegaran Tuna Loin

Identifikasi kesegaran tuna loin menggunakan sensor gas MQ4, MQ136, dan MQ137, yang dirangkai dengan *IC ATMEGA Arduino Uno*. Rangkaian sensor ini digunakan untuk mengakuisisi tingkat bau dari tuna loin. Arduino Uno dirangkaikan dengan laptop untuk membaca nilai sensor gas tersebut sebagai nilai bau tuna loin.

#### b. Alat untuk mengukur kadar gas amonia *Ammonia Analyzer* AR 8500, alat mengukur kadar gas *hydrogen sulfide* Wintact WT882, dan alat mengukur kadar gas *methane* MESTEK CDGA02A.

#### c. Identifikasi Kandungan Lemak Tuna Loin

Identifikasi kandungan lemak tuna loin menggunakan sensor *spectrometry Sparkfun AS 7265*. Fitur lemak dideteksi dengan sensor spektrometer *AS7263*, yang menggunakan gelombang elektromagnetik *near infrared 6-channel multi-spectral* untuk menentukan komposisi lemak tuna loin. Arduino Uno dirangkaikan dengan laptop untuk membaca nilai sensor *spectrometry* tersebut sebagai nilai kandungan lemak tuna loin.

#### d. Akuisisi Citra Tuna Loin

Akuisisi citra menggunakan web camera 4 MP untuk mendapatkan kualitas citra yang baik. *Web camera CAMTECH CT50 QHD 1440P 2K 4MP Auto Focus* dengan spesifikasi sebagai berikut

Resolusi video: 2560 x 1440 pixel

Resolusi maksimum: 1440p/30fps - 720p/30fps

Kamera: 4 Megapixel

*Field of view:* 90°

Format Data: MJPG /YUY2

*Image control: auto focus, auto white balance, auto exposure*

Jarak *auto focus*: >70MM

*Aperture*: 2,5

*Voltage*: 5V 130mA

Temperatur kerja: -20-60°C

Laptop dengan spesifikasi sebagai berikut

Processor Intel Core i7

Memory 16 GB DDR3

VGA: NVidia GeForce

Hard Disk: SSD 500 GB

#### 4.7.2 Perangkat Lunak

Perangkat Lunak yang digunakan untuk membangun sistem sebagai berikut:

- a. Sistem Operasi Windows 10
- b. Bahasa Pemrograman C# (Visual Studio)
- c. IDE dengan *Jupyter Notebook* versi 9
- d. Bahasa pemrograman Python dengan Tensorflow library
- e. PHP MySQL
- f. Sofware *Scratch* sebagai IDE Arduinio Uno

Adapun mekanisme pengujian keluaran sistem sebagai berikut:

- a. Kalibrasi sensor gas dilakukan berdasarkan grafik karakteristik sensitivitas sensor yang diperoleh pada *datasheet* setiap sensor gas(Petric et al., 2019) (ShowRange, n.d.), sehingga diperoleh nilai ppm gas.
- b. Verifikasi nilai sensor menggunakan instrumen pengukuran gas amonia, gas methan dan hidrogen sulfida.
- c. Data uji diakuisisi dengan menggunakan sensor bau, sensor *spectrometry*, dan *web camera*. Data uji selanjutnya di ekstraksi fitur bau, fitur kandungan lemak, fitur warna dan fitur tekstur. Fitur uji digabungkan dan selanjutnya melalui proses pencocokan dengan bobot pelatihan.
- d. Pencocokan data uji menggunakan pencocokan fitur menggunakan algoritma *euclidean distance*.

- e. Pengukuran unjuk kerja model penentuan tuna loin menggunakan metode *confusion matrix*.

#### **4.8 Prosedur Penelitian**

Penelitian untuk mengenali kualitas *grade* tuna loin ini mengikuti mekanisme tahapan siklus hidup pengembangan sistem. Adapun prosedur dalam penelitian sebagai berikut:

a. Tahap Analisis

Pada tahap ini dilakukan penentuan kebutuhan terhadap model sistem yang akan dikembangkan meliputi instrumen untuk akuisisi data, berupa sensor gas untuk akuisisi bau terkait kesegaran loin, sensor spektrometri untuk akuisisi tingkat kandungan lemak pada loin dan akuisisi citra loin dengan *webcamera*. Pada tahap ini menganalisis data yang terlibat dalam sistem baik masukan, keluaran, pengguna sistem serta proses yang diperlukan untuk mengolah data.

b. Tahap Desain

Pada tahapan ini dilakukan proses perancangan alat untuk mengekstraksi fitur daging tuna loin dan pengembangan sistem meliputi pembuatan basis data, perancangan algoritma, dan perancangan antarmuka sebagai media interaksi antara pengguna dan sistem.

c. Tahapan Pengkodean

Pada tahapan ini dilakukan proses pengkodean rancangan algoritma menggunakan instrumen perangkat keras dan perangkat lunak untuk membangun sistem berbasis *neural network* untuk mengenali kualitas *grading* tuna loin.

d. Tahapan Pengujian

Pada tahapan ini dilakukan proses pengujian sistem untuk menentukan unjuk kerja sistem, apakah terdapat penyesuaian dan perbaikan sistem ataukah sistem siap diimplementasikan.

e. Tahapan Analisis Korelasi Variabel Penelitian

Pada tahapan ini dilakukan proses analisis pengaruh variabel independen terhadap variabel dependen untuk menguji kebenaran hipotesis yaitu pengaruh setiap variabel fitur profil bau, fitur kandungan lemak, fitur citra warna, fitur tekstur terhadap *grade* tuna loin dan pengaruh semua variabel

fitur profil bau, kandungan lemak, citra warna, tekstur terhadap *grade* tuna loin.



Gambar 4.19 Siklus Hidup Pengembangan Sistem  
 (Sumber: <https://salamadian.com/sdlc-system-development-life-cycle/>)

#### 4.9 Cara Analisa Data

Berdasarkan data sampel penelitian yang telah diakuisisi, selanjutnya dilakukan pengolahan dan analisa data sebagai berikut:

- a. Data hasil pengukuran sensor gas yang diperoleh selanjutnya dinormalisasi untuk mendapatkan fitur bau. Fitur bau berupa tiga nilai hasil pengukuran sensor gas terhadap kandungan *ammonia*, *methana* dan asam sulfat dari daging tuna loin.
- b. Data hasil pengukuran sensor spektrometri yang diperoleh selanjutnya di normalisasi untuk mendapatkan fitur lemak. Fitur bau berupa deretan angka yang terdiri dari enam nilai hasil pengukuran sensor spektrometer terhadap tuna loin.
- c. Citra loin yang telah diakuisisi selanjutnya di *pre-processing* dalam ruang warna RGB dikonversi menjadi HSV dan selanjutnya di normalisasi. Fitur citra tersebut berupa deretan angka intensitas citra setelah dinormalisasi. Rumus perhitungannya mengacu kepada sub bab 4.2.8.
- d. Citra loin yang telah diakuisisi selanjutnya dipre-*processing* dalam ruang warna *grayscale* dan selanjutnya diolah menggunakan algoritma *Gray Level Co-occurrence Matrix*. Fitur tekstur terdiri dari deretan nilai berupa *angular second*

*moment* (ASM), kontras, *inverse different moment* (IDM), entropi dan korelasi yang rumus perhitungannya mengacu kepada sub bab 4.2.10.

- e. Semua fitur diatas digabungkan dan selanjutnya dilatih menggunakan *deep learning neural network* untuk mengenali grade tuna loin yang ada yaitu grade #1, #2+, #2, #3, sehingga diperoleh bobot pelatihan. Selain itu fitur pelatihan di klasifikasikan menggunakan algoritma k-NN.
- f. Sampel uji berupa loin di akuisisi mengikuti tahapan a sampai e, selanjutnya fitur sampel uji dibandingkan dengan bobot pelatihan, sehingga sampel uji dikenali kelas *gradenya* berdasarkan jarak terpendek *euclidean distance* dari sampel uji dengan masing masing bobot pelatihan. Jarak terpendek dari *Euclidean distance* menunjukkan sampel uji tersebut diklasifikasikan ke dalam sampel dengan jarak terpendek.
- g. Fitur bau, fitur lemak, fitur citra warna, dan fitur tekstur sampel dikorelasi dengan kualitas grade tuna loin.
- h. Unjuk kerja model penentuan kesegaran ikan diukur menggunakan teknik *confusion matrix*. Unjuk kerja algoritma *deep learning neural network* dibandingkan dengan algoritma k-NN. Akurasi klasifikasi model *neural network* mengacu kepada sub bab 4.2.13.

Teknik analisis data dalam penelitian kuantitatif menggunakan statistik, dan terdapat dua macam model statistik untuk analisis data yaitu statistik deskriptif dan statistik inferensial. Statistik deskriptif bertujuan untuk menganalisis data dengan cara menggambarkan data yang telah terkumpul sebagaimana adanya tanpa bertujuan untuk membuat kesimpulan yang berlaku umum (generalisasi), sedangkan statistik inferensial adalah teknik statistik yang bertujuan untuk menganalisis data sampel dan hasilnya diberlakukan umum untuk populasi. Statistik inferensial cocok diterapkan bila sampel diambil dari populasi yang jelas dan teknik pengambilan sampel dari populasi dilakukan secara *random* (Sugiyono, 2018). Dengan demikian model analisis data yang sesuai pada penelitian ini menggunakan statistik inferensial karena sampel diambil secara *random* dan kesimpulan yang diberlakukan untuk populasi memiliki peluang kebenaran(kepercayaan) dan peluang kesalahan.

Berdasarkan sub bab 3.3, hipotesis penelitian ini menggunakan jenis hipotesis asosiatif (memiliki korelasi), dan penelitian ini menggunakan 4 variabel independen dan 1 variabel dependen, dan jenis data penelitian ini berupa fitur data sampel ternormalisasi sehingga masuk ke dalam jenis data rasio. Untuk jenis hipotesis asosiatif dan jenis data rasio, pengujian hipotesis menggunakan metode korelasi produk *moment* dan korelasi ganda. Korelasi produk *moment* digunakan untuk menguji hipotesis hubungan satu variabel independen dengan satu variabel dependen(Sugiyono, 2018). Korelasi ganda digunakan untuk menguji hipotesis mengenai hubungan dua variabel independen atau lebih secara bersama sama dengan satu variabel dependen(Sugiyono, 2018).

## DAFTAR PUSTAKA

- Afzal, S. (n.d.). *I2C Timing: Definition and Specification Guide*. Analog Devices.
- Agustyawan, A. (2021). Pengolahan Citra untuk Membedakan Ikan Segar dan Tidak Segar Menggunakan Convolutional Neural Network. *Indonesian Journal of Applied Informatics*, 5(1). <https://doi.org/10.20961/ijai.v5i1.41770>
- Airlangga, F. U. (2019). *Total Volatile Base (TVB)*. <Https://Fpk.Unair.Ac.Id/>. <https://fpk.unair.ac.id/total-volatile-base-tvb/>
- Amazon.co.uk. (1996). *HUABAN IPCS MQ-136 MQ136 Hydrogen Sulfide H2S Detection Gas Sensor Module with Alarm Signal Light*. Amazon.Co.Uk. <https://www.amazon.co.uk/HUABAN-MQ-2-MQ-135-Sensor-Module/dp/B089SQDQFJ?th=1>
- Amongsari, L., Kuswandi, B., & Kristiningrum, N. (2020). Pengembangan Sensor Kesegaran Edible untuk Fillet Ikan Tuna (*Thunnus albacares*) Berbasis Antosianin Kulit Buah Juwet (*Syzygium cumini*) dengan Membran Selulosa Bakterial. *Pustaka Kesehatan*, 8(2), 66. <https://doi.org/10.19184/pk.v8i2.11460>
- Anvy, J., Damayanti, A., & Pratiwi, A. B. (2020). Clustering of fish freshness using discrete wavelet transform and Kohonen self organizing map. *Journal of Physics: Conference Series*, 1494(1). <https://doi.org/10.1088/1742-6596/1494/1/012008>
- Arraffi Birahmatika, R., & M. T. Nasution, A. (2016). Rancang Bangun Pencitraan Multispektral Cahaya Tampak untuk Deteksi Kesegaran Ikan Gurami (*Oosphronemus goramy*). *Jurnal Otomasi Kontrol Dan Instrumentasi*, 8(2). <https://doi.org/10.5614/joki.2016.8.2.10>
- Asmara, R. A., Puspitasri, D., Romlah, S., H, Q., & Romario, R. (2017). Identifikasi Kesegaran Daging Sapi Berdasarkan Citranya Dengan Ekstraksi Fitur Warna dan Teksturnya Menggunakan Metode Gray Level Co-Occurrence Matrix. *Prosiding SENTIA*, 9.
- Astutik, F. (2015). Sistem Pengenalan Kualitas Ikan Gurame Dengan Wavelet, Pca, Histogram Hsv Dan Knn. *Lontar Komputer*, 4(3), 336–346. <https://doi.org/10.24843/LKJITI>
- Atmaja, H. (2017). *Ekstraksi Fitur Tekstur*. <https://docplayer.info/58969244-Ekstraksi-fitur-tekstur.html>
- Bartam, P., Garrod, P., & Kaneko, J. (1996). *Quality and Product Differentiation as Price Determinants in the Marketing of Fresh Pacific Tuna and Marlin*. Joint Institute for Marine and Atmospheric Research.
- Bermúdez, J. R., López-Estrada, F. R., Besançon, G., Torres, L., & Santos-Ruiz, I. (2020). Leak-Diagnosis Approach for Water Distribution Networks based on a k-NN Classification Algorithm. *IFAC-PapersOnLine*, 53(2), 16651–16656.

- <https://doi.org/10.1016/j.ifacol.2020.12.795>
- Buniyamin, N., Ringgau, D., Mohamad, Z., & Murat, Z. H. (2011). Non-Destructive Fish Fat Detection Using Infrared Sensor. *International Conference on Food Engineering and Biotechnology*, 9, 33–37.
- Catur Pramono Adi, Tina Fransiskha C.P., Panjaitan, P., & Yuda Herdiansyah. (2021). Pembuatan prototipe penentu kesegaran ikan patin Berbasis sensor TCS 230. *Jurnal Airaha*, 10(01), 123–130. <https://doi.org/10.15578/ja.v10i01.242>
- Cheng, J. H., & Sun, D. W. (2015). Data fusion and hyperspectral imaging in tandem with least squares-support vector machine for prediction of sensory quality index scores of fish fillet. *LWT*, 63(2). <https://doi.org/10.1016/j.lwt.2015.04.039>
- Cheng, J. H., Sun, D. W., Pu, H., & Zhu, Z. (2015). Development of hyperspectral imaging coupled with chemometric analysis to monitor K value for evaluation of chemical spoilage in fish fillets. *Food Chemistry*, 185. <https://doi.org/10.1016/j.foodchem.2015.03.111>
- Cheng, J. H., Sun, D. W., Qu, J. H., Pu, H. Bin, Zhang, X. C., Song, Z., Chen, X., & Zhang, H. (2016). Developing a multispectral imaging for simultaneous prediction of freshness indicators during chemical spoilage of grass carp fish fillet. *Journal of Food Engineering*, 182. <https://doi.org/10.1016/j.jfoodeng.2016.02.004>
- Cui, J., & Cui, C. (2021). Non-destructive evaluation of salmon and tuna freshness in a room-temperature incubation environment using a portable visible/near-infrared imaging spectrometer. *Transactions of the ASABE*, 64(2). <https://doi.org/10.13031/TRANS.14220>
- Daraz. (2022). *MQ137 Ammonia Gas Detection Sensor Module*. Daraz.Com. <https://www.daraz.com.bd/products/mq137-ammonia-gas-detection-sensor-module-5-to-500ppm-for-i181205578.html>
- Davidegironi. (2018). *Presenting MQ sensors: low-cost gas and pollution detectors*. OpenElectronics. <https://www.open-electronics.org/presenting-mq-sensors-low-cost-gas-and-pollution-detectors/>
- Department of Fisheries Government of Western Australia. (2002). *Guidelines for Seafood* (Issue February). <https://seafoodacademy.org/pdfs/seafood-retailers-guidelines.pdf>
- DiGregorio, R. (2012). *Tuna Grading and Evaluation* (M. ZicarelTi (ed.); First Edit). Urner Barry.
- Dowlati, M., de la Guardia, M., Dowlati, M., & Mohtasebi, S. S. (2012). Application of machine-vision techniques to fish-quality assessment. In *TrAC - Trends in Analytical Chemistry* (Vol. 40). <https://doi.org/10.1016/j.trac.2012.07.011>
- Dwiyanto, S., Iksal, & Nugraha, S. (2018). Alat Pendekripsi Kesegaran Ikan

- Menggunakan Metode K-Nearest Neighbor Berdasar Warna Mata Berbasis ATMega 328. *Jurnal PROSISKO*, 5(2), 127–135.
- DZY Instrument. (n.d.). *Witact WT8822 Detektor Hidrogen Sulfida*. Retrieved July 3, 2022, from [https://id.aliexpress.com/item/4000046781923.html?spm=a2g0o.productlist.0.0.553e45268kEBU0&algo\\_pvid=b7609f68-caee-45ef-924c-4766a0c41b2f&algo\\_exp\\_id=b7609f68-caee-45ef-924c-4766a0c41b2f-13&pdp\\_ext\\_f=%257B%2522sku\\_id%2522%253A%252210000003390990954%2522%257D&pdp\\_npi=2%25](https://id.aliexpress.com/item/4000046781923.html?spm=a2g0o.productlist.0.0.553e45268kEBU0&algo_pvid=b7609f68-caee-45ef-924c-4766a0c41b2f&algo_exp_id=b7609f68-caee-45ef-924c-4766a0c41b2f-13&pdp_ext_f=%257B%2522sku_id%2522%253A%252210000003390990954%2522%257D&pdp_npi=2%25)
- Eka Putra, W. S. (2016). Klasifikasi Citra Menggunakan Convolutional Neural Network (CNN) pada Caltech 101. *Jurnal Teknik ITS*, 5(1). <https://doi.org/10.12962/j23373539.v5i1.15696>
- Electronics, S. (n.d.). *SparkFun Spectral Sensor Breakout - AS7263 NIR (Qwiic)*. Retrieved December 1, 2021, from <https://www.sparkfun.com/products/14351>
- Esculenta, M., & Faqih, A. (2019). Analisis Pembacaan Sensor Alkohol Terhadap Variasi Jarak Pada Pengemudi Untuk Mengurangi Potensi Kecelakaan. *Jurnal ELTEK*, 17(01).
- FAO. (1989). *Sensory Assessment*. FAO. <https://www.fao.org/3/x5989e/X5989e01.htm>
- Firdaus, M. (2019). Profil Perikanan Tuna Dan Cakalang Di Indonesia. *Buletin Ilmiah Marina Sosial Ekonomi Kelautan Dan Perikanan*, 4(1), 23. <https://doi.org/10.15578/marina.v4i1.7328>
- Fitriyah, H., Syauqy, D., & Susilo, F. A. (2020). Deteksi Kesegaran Ikan Tongkol (*Euthynnus Affinis*) secara Otomatis Berdasarkan Citra Mata Menggunakan Binary Similarity. *Jurnal Teknologi Informasi Dan Ilmu Komputer*, 7(5), 879. <https://doi.org/10.25126/jtiik.2020753839>
- Franceschelli, L., Berardinelli, A., Dabbou, S., Ragni, L., & Tartagni, M. (2021). Sensing technology for fish freshness and safety: A review. In *Sensors (Switzerland)* (Vol. 21, Issue 4). <https://doi.org/10.3390/s21041373>
- Franceschelli, L., Cevoli, C., Benelli, A., Iaccheri, E., Tartagni, M., & Berardinelli, A. (2020). Vis/NIR hyperspectral imaging to assess freshness of sardines (*Sardina pilchardus*). *2020 IEEE International Workshop on Metrology for Agriculture and Forestry, MetroAgriFor 2020 - Proceedings*. <https://doi.org/10.1109/MetroAgriFor50201.2020.9277603>
- Gourmets, L. (2021). *Sushi Grade Tuna: The Grading System*. LUXE GOURMETS. <https://www.luxegourmets.com/chefs-column/tuna-grading-system>
- Han, F., Huang, X., Teye, E., Gu, H., Dai, H., & Yao, L. (2014). A nondestructive method for fish freshness determination with electronic tongue combined with linear and non-linear multivariate algorithms. *Czech Journal of Food Sciences*,

- 32(6), 532–537. <https://doi.org/10.17221/88/2014-cjfs>
- Han, F. K., Huang, X. Y., Mu, L. J., & Gu, H. Y. (2014). Quantitative and qualitative analysis of fish freshness based on electronic tongue technique. *Modern Food Science and Technology*, 30(7).
- Hartanto, T. R., & Suharno1, B. (2021). *Daya Saing Ekspor Ikan Tuna Cakalang Tongkol Indonesia- Export Competitiveness of Indonesian Tunas-Skipjack Tunas-Eastern Littles Tunas in The United States of America 's Market Bahan dan Alat.* 24(2), 227–235.
- Hestiningsih, I. (2008). *Pengolahan Citra.* Informatika.
- Hidayat, A. (2012). *Hipotesis Penelitian Adalah: Penjelasan Lengkap.* 14 Oktober. <https://www.statistikian.com/2012/10/hipotesis.html>
- Hidayat, A. (2017). *Teknik Sampling Dalam Penelitian (Penjelasan Lengkap Serta Jenisnya).* <https://www.statistikian.com/2017/06/teknik-sampling-dalam-penelitian.html>
- Humas BRSDM. (2021). Jurus Menghadapi Penolakan Produk Perikanan Indonesia di Pasar Global. *Kementerian Kelautan Dan Perikanan.* <https://kkp.go.id/artikel/30433-jurus-menghadapi-penolakan-produk-perikanan-indonesia-di-pasar-global>
- IBM. (n.d.). <https://www.ibm.com/id-en/topics/knn>. Retrieved July 5, 2022, from <https://www.ibm.com/id-en/topics/knn>
- Indahwati, E., & Nurhayati. (2012). Rancang Bangun Alat Pengukur Konsentrasi Gas Karbon Monoksida(CO) Menggunakan Sensor Gas MQ-135 Berbasis Mikrokontroller Dengan Komunikasi Serial USART. *Jurnal Teknik Elektro*, 1(1), 12–21. <https://jurnalmahasiswa.unesa.ac.id/index.php/jurnal-teknik-elektro/article/download/209/143>
- Ismail, A. M. (2018). *Cara Kerja Algoritma k-Nearest Neighbor (k-NN).* Bee Solution Partners. <https://medium.com/bee-solution-partners/cara-kerja-algoritma-k-nearest-neighbor-k-nn-389297de543e>
- Jarmin, R., Khuan, L. Y., Hashim, H., & Rahman, N. H. A. (2012). A comparison on fish freshness determination method. *Proceedings of the 2012 International Conference on System Engineering and Technology, ICSET 2012.* <https://doi.org/10.1109/ICSEngT.2012.6339329>
- Kadir, A., & Susanto, A. (2013). *Teori dan Aplikasi Pengolahan Citra.* Andi Offset.
- Kaiang, D. B., Montolalu, L. A., & Montolalu, R. I. (2016). Kajian Mutu Ikan Tongkol (Euthynnus Affinis) Asap Utuh Yang DIkemas Vakum Dan Non Vakum Selama 2 Hari Penyimpanan Pada Suhu Kamar. *MEDIA TEKNOLOGI HASIL PERIKANAN*, 4(2). <https://doi.org/10.35800/mthp.4.2.2016.13034>
- Khansa, S. (2020). PENERAPAN EKSTRAKSI CIRI TRANSFORMASI WAVELET

DALAM PEMBUATAN MODEL KLASIFIKASI KESEGARAN IKAN SELAR. *Senamika.*

- Khodabakhshian, R., Emadi, B., Khojastehpour, M., Golzarian, M. R., & Sazgarnia, A. (2017). Non-destructive evaluation of maturity and quality parameters of pomegranate fruit by visible/near infrared spectroscopy. *International Journal of Food Properties*, 20(1). <https://doi.org/10.1080/10942912.2015.1126725>
- Khodabux, K., L’Omelette, M. S. S., Jhaumeer-Laulloo, S., Ramasami, P., & Rondeau, P. (2007). Chemical and near-infrared determination of moisture, fat and protein in tuna fishes. *Food Chemistry*, 102(3). <https://doi.org/10.1016/j.foodchem.2006.05.057>
- Khoshnoudi-Nia, S., & Moosavi-Nasab, M. (2019). Prediction of various freshness indicators in fish fillets by one multispectral imaging system. *Scientific Reports*, 9(1). <https://doi.org/10.1038/s41598-019-51264-z>
- Kim, P. (2017). MATLAB Deep Learning. In *MATLAB Deep Learning*. <https://doi.org/10.1007/978-1-4842-2845-6>
- Kumar, D., & Kumar, S. (2020). An Intelligent System for Fish Freshness Quality Assessment Using Artificial Neural Network. *International Journal Of Creative Research Thoughts (IJCRT)*, 8(2), 765–958.
- Laboratory, M. E. (2020). *Hydron Ammonia Test Paper*. Micro Essential Laboratory Inc. <https://www.microessentiallab.com/ProductInfo/F30-SPLTY-AMMONI-SRD.aspx>
- Lalabadi, H. M., Sadeghi, M., & Mireei, S. A. (2020). Fish freshness categorization from eyes and gills color features using multi-class artificial neural network and support vector machines. *Aquacultural Engineering*, 90. <https://www.sciencedirect.com/science/article/pii/S0144860919301761>
- Lan, W., Liu, J., Hu, X., Xiao, L., Sun, X., & Xie, J. (2021). Evaluation of quality changes in big-eye tuna (*Thunnus obesus*) based on near-infrared reflectance spectroscopy (NIRS) and low field nuclear magnetic resonance (LF-NMR). *Journal of Food Process Engineering*, 44(2). <https://doi.org/10.1111/jfpe.13613>
- Leghrif, R., Aantri, Y., Sanchez, J. B., Berger, F., & Kaaya, A. (2020). Assessing the freshness of Agadir blue fish using a metal oxide gas sensing array. *Materials Today: Proceedings*, 22. <https://doi.org/10.1016/j.matpr.2019.08.054>
- Li, P., Niu, Z., Shao, K., & Wu, Z. (2021). Quantitative analysis of fish meal freshness using an electronic nose combined with chemometric methods. *Measurement: Journal of the International Measurement Confederation*, 179. <https://doi.org/10.1016/j.measurement.2021.109484>
- Li, P., Ren, Z., Shao, K., Tan, H., & Niu, Z. (2019). Research on distinguishing fish meal quality using different characteristic parameters based on electronic nose technology. *Sensors (Switzerland)*, 19(9). <https://doi.org/10.3390/s19092146>

- Lintang, C. A., Widodo, T. W., & Lelono, D. (2016). Rancang Bangun Electronic Nose untuk Mendeteksi Tingkat Kebusukan Ikan Air Tawar. *IJEIS (Indonesian Journal of Electronics and Instrumentation Systems)*, 6(2). <https://doi.org/10.22146/ijeis.15251>
- Lintang, C. J., Labaro, I. L., & Telleng, A. T. R. (2012). Kajian musim penangkapan ikan tuna dengan alat tangkap hand line di Laut Maluku. *JURNAL ILMU DAN TEKNOLOGI PERIKANAN TANGKAP*, 1(1). <https://doi.org/10.35800/jitpt.1.1.2012.700>
- Lu, Y. C., Tung, C., & Kuo, Y. F. (2020). Identifying the species of harvested tuna and billfish using deep convolutional neural networks. *ICES Journal of Marine Science*, 77(4). <https://doi.org/10.1093/icesjms/fsz089>
- Madenda, S. (2013). Pengolahan Citra dan Video Digital. In *Teori Aplikasi dan Pemrograman Menggunakan Matlab*.
- Massaro, A., Stella, R., Negro, A., Bragolusi, M., Miano, B., Arcangeli, G., Biancotto, G., Piro, R., & Tata, A. (2021). New strategies for the differentiation of fresh and frozen/thawed fish: A rapid and accurate non-targeted method by ambient mass spectrometry and data fusion (part A). *Food Control*, 130. <https://doi.org/10.1016/j.foodcont.2021.108364>
- Mazwani Abdullah, Jamari, A. Z., Daril, M. A. M., Wahab, M. I. A., & Abdullah, K. S. & S. M. (2022). Sustainable IoT-Based Environmental and Industrial Monitoring System. In *Advanced Transdisciplinary Engineering and Technology*. Springer Link. [https://link.springer.com/chapter/10.1007/978-3-031-01488-8\\_16](https://link.springer.com/chapter/10.1007/978-3-031-01488-8_16)
- Medeiros, E. C., Almeida, L. M., & Filho, J. G. de A. T. (2021). Computer vision and machine learning for tuna and salmon meat classification. *Informatics*, 8(4). <https://doi.org/10.3390/informatics8040070>
- Mestek. (n.d.). *MESTEK CDGA02A*.
- Misimi, E., Øye, E. R., Sture, Ø., & Mathiassen, J. R. (2017). Robust classification approach for segmentation of blood defects in cod fillets based on deep convolutional neural networks and support vector machines and calculation of gripper vectors for robotic processing. *Computers and Electronics in Agriculture*, 139. <https://doi.org/10.1016/j.compag.2017.05.021>
- Moon, E. J., Kim, Y., Xu, Y., Na, Y., Giaccia, A. J., & Lee, J. H. (2020). Evaluation of salmon, tuna, and beef freshness using a portable spectrometer. *Sensors (Switzerland)*, 20(15). <https://doi.org/10.3390/s20154299>
- Naimullah, M., Sthevanie, F., & Ramadhani, K. N. (2020). Tuna Meat Grade Classification Using Color Histogram and Grey Level co-Occurrence Matrix. *E-Proceeding of Engineering*, 8483–8492. <https://repository.telkomuniversity.ac.id/pustaka/161771/tuna-meat-grade-classification-using-color-histogram-and-grey-level-co-occurrence-matrix.html>

- Najib, M. S., Zamberan, N. H., Zahed, N., Halim, F. A., Zahari, M. F., Mamat, W. M. A., & Manap, H. (2016). Fish quality study using odor-profile case-based reasoning (CBR) classification technique. *ARPN Journal of Engineering and Applied Sciences*, 11(10), 6691–6696.
- Nasional.kontan.co.id. (2021, September 29). Indonesia eksport tuna lewat platform e-Commerce. *Nasional.Kontan.Co.Id.* <https://nasional.kontan.co.id/news/indonesia-eksport-tuna-lewat-platform-e-commerce>
- Nasional, B. S. (2006). *Petunjuk pengujian organoleptik dan atau sensori*. Badan Standadrisasi Nasional. [https://kupdf.net/download/sni-01-2346-2006-petunjuk-pengujian-organoleptik-dan-atau-sensori\\_59ae44b0dc0d60f00a568ede\\_pdf](https://kupdf.net/download/sni-01-2346-2006-petunjuk-pengujian-organoleptik-dan-atau-sensori_59ae44b0dc0d60f00a568ede_pdf)
- Navotas, I. C., Santos, C. N. V., Balderrama, E. J. M., Candido, F. E. B., Villacanas, A. J. E., & Velasco, J. S. (2018). Fish identification and freshness classification through image processing using artificial neural network. *ARPN Journal of Engineering and Applied Sciences*, 13(18), 4912–4922.
- Noaa. (2018). FACT SHEET U . S . Seafood Import Monitoring Program. *FACT SHEET U . S . Seafood Import Monitoring Program*, November, 1–3.
- Novaković, J. D., Veljović, A., Ilić, S. S., Papić, Ž., & Milica, T. (2017). Evaluation of Classification Models in Machine Learning. *Theory and Applications of Mathematics & Computer Science*, 7(1).
- Novianto, T. D., & Erawan, I. M. S. (2020). Perbandingan Metode Klasifikasi pada Pengolahan Citra Mata Ikan Tuna. *Prosiding SNFA (Seminar Nasional Fisika Dan Aplikasinya)*, 5. <https://doi.org/10.20961/prosidingsnfa.v5i0.46615>
- Nugroho, P. A., Fenriana, I., & Arijanto, R. (2020). IMPLEMENTASI DEEP LEARNING MENGGUNAKAN CONVOLUTIONAL NEURAL NETWORK ( CNN ) PADA EKSPRESI MANUSIA. *Algor.*
- Nurhayati, T., Abdullah, A., & Sari, S. N. (2019). Penentuan Formaldehid Ikan Beloso (Saurida tumbil) Selama Penyimpanan Beku. *Jurnal Pengolahan Hasil Perikanan Indonesia*, 22(2).
- Nurjanah, Abdullah, A., Naibaho, I., Kartikayani, D., Nurilmala, M., Yusfiandayani, R., & Sondita, M. F. A. (2019). Fish quality and nutritional assessment of yellowfin tuna (*Thunnus albacares*) during low temperature storage. *IOP Conference Series: Earth and Environmental Science*, 404(1). <https://doi.org/10.1088/1755-1315/404/1/012074>
- Oni, M., Kanata, B., & Ratnasari, D. (2021). Menentukan Luas Objek Citra Dengan Teknik Segmentasi Berdasarkan Warna Pada Ruang Warna HSV. *Dielektrika*, 8(2), 138. <https://dielektrika.unram.ac.id/index.php/dielektrika/article/view/274>
- OpenCV. (2021). *Color conversions*. Doxygen. [https://docs.opencv.org/3.4/de/d25/imgproc\\_color\\_conversions.html](https://docs.opencv.org/3.4/de/d25/imgproc_color_conversions.html)

- Ordoñez, A., Eikvil, L., Salberg, A. B., Harbitz, A., Murray, S. M., & Kampffmeyer, M. C. (2020). Explaining decisions of deep neural networks used for fish age prediction. *PLoS ONE*, 15(6). <https://doi.org/10.1371/journal.pone.0235013>
- Pakaya, R., & Suleman, S. (2018). PENGELOMPOKKAN KUALITAS DAGING IKAN TUNA DENGAN K-MEANS BERBASIS HISTOGRAM DERAJAT KEABUAN. *Jurnal Technopreneur (JTech)*. <https://doi.org/10.30869/jtech.v6i2.207>
- Pamungkas, A. (2016). *Model Ruang Warna Pengolahan Citra*. <https://pemrogramanmatlab.com/2016/06/08/model-ruang-warna-pengolahan-citra/>
- Pamungkas, A. (2018). *Analisis Tekstur Menggunakan Metode GLCM, LBP, dan FLBP*. *Pemrograman Matlab*. <https://pemrogramanmatlab.com/2018/09/27/analisis-tekstur-menggunakan-metode-glcm-lbp-dan-flbp/>
- Patty, C. N., Dotulong, V., & Suwetja, I. K. (2015). Mutu Ikan Roa (Hemirhamphus sp.) Asap Yang Ada Di Pasar Tradisional Di Kota Manado Yang Disimpan Pada Suhu Ruang. *Media Teknologi Hasil Perikanan*, 3(2). <https://doi.org/10.35800/mthp.3.2.2015.10354>
- Petric, M., Dodigovic, F., Grcic, I., & Markuzic, P. (2019). Ammonia Concentration Monitoring Using Arduino Platform. *EnvEng-IO*, 6(1).
- Pramunendar, R. A., Wibirama, S., & Santosa, P. I. (2019). Fish classification based on underwater image interpolation and back-propagation neural network. *Proceedings - 2019 5th International Conference on Science and Technology, ICST 2019*. <https://doi.org/10.1109/ICST47872.2019.9166295>
- Prasanth, P., Viswan, G., & Bennaceur, K. (2019). Development of a low-cost portable spectrophotometer for milk quality analysis. *Materials Today: Proceedings*, 46, 4863–4868. <https://doi.org/10.1016/j.matpr.2020.10.327>
- Prasetyo, E., Purbaningtyas, R., Adityo, R. D., Prabowo, E. T., & Ferdiansyah, A. I. (2021). Perbandingan Convolution Neural Network Untuk Klasifikasi Kesegaran Ikan Bandeng Pada Citra Mata. *Jurnal Teknologi Informasi Dan Ilmu Komputer*, 8(3), 601. <https://doi.org/10.25126/jtiik.2021834369>
- Prasmatio, R. M., Rahmat, B., & Yuniar, I. (2020). Deteksi Dan Pengenalan Ikan Menggunakan Algoritma Convolutional Neural Network. *Jurnal Informatika Dan Sistem Informasi (JIFoSI)*, 1(2 SE-Articles).
- Prayogi, Y. R., & Wibisono, C. L. (2019). Implementasi Pengolahan Citra Digital Untuk Deteksi Kesegaran Ikan Menggunakan Perangkat Android. In *Prosiding Seminar Nasional Teknologi dan Sains (SNasTekS)* (Issue September, pp. 447–454).
- Pusdik.kkp.go.id. (2019). *Teknik Penanganan Hasil Budidaya Perikanan*,

*Kemunduran Mutu Hasil Perikanan.* Pusdik.Kkp.Go.Id.  
<http://www.pusdik.kkp.go.id/elearning/index.php/modul/read/190114-183412uraian-c-materi>

- Qin, J., Vasefi, F., Hellberg, R., Akhbardeh, A., Isaacs, R., Yilmaz, A. G., Hwang, C., Baek, I., Schmidt, W. F., & Kim, M. S. (2020). *Inspecting species and freshness of fish fillets using multimode hyperspectral imaging techniques.* <https://doi.org/10.1117/12.2558684>
- Rahmawati, L., Achmad Maulana Hakimuddin, & Izzatul Umami. (2020). Implementasi Sensor Gas MQ-136 Dan MQ-137 Untuk Mendeteksi Kesegaran Daging Sapi Menggunakan Metode Neural Network. *Jurnal Intake : Jurnal Penelitian Ilmu Teknik Dan Terapan*, 12(1). <https://doi.org/10.48056/jintake.v12i1.138>
- Ramadhan, M. D., & Setiyono, B. (2019). Pengolahan Citra untuk Mengetahui Tingkat Kesegaran Ikan Menggunakan Metode Transformasi Wavelet Diskrit. *Jurnal Sains Dan Seni ITS*, 8(1). <https://doi.org/10.12962/j23373520.v8i1.37715>
- Rees52. (2021). *How To Detect Smoke And Inflammable Gases Using MQ-4 Gas Sensor Interfacing With Arduino Uno - KT989.* Rees52. <https://rees52.com/diy-arduino/1146-how-to-detect-smoke-and-inflammable-gases-using-mq-4-gas-sensor-interfacing-with-arduino-uno-ab048>
- Rivai, M., Misbah, Attamimi, M., Firdaus, M. H., Tasripan, & Tukadi. (2019). Fish Quality Recognition using Electrochemical Gas Sensor Array and Neural Network. *2019 International Conference on Computer Engineering, Network, and Intelligent Multimedia, CENIM 2019 - Proceeding, 2019-Novem.* <https://doi.org/10.1109/CENIM48368.2019.8973369>
- Rohim, A., Sari, Y. A., & Tibyani. (2019). Convolution neural network (cnn) untuk pengklasifikasian citra makanan tradisional. *Jurnal Pengembangan Teknologi Informasi Dan Ilmu Komputer.*
- Rokhmayanti, & Heryantoro, L. (2017). Penyelidikan Kejadian Luar Biasa(KLB) Keracunan Makanan Di Kabupaten Gunung Kidul Daerah Istimewa Yogyakarta. *Jurnal Formil*, 2.
- S.Made, N. . (2018). Kadar Total Volatile Base,Glikogen, Katepsin Dan Water Holding Capacity Daging Ikan Nila (*Oreochromis niloticus*) Pada Fase Kemunduran Mutu. *MARINADE*, 01(01).
- SANTHI, D. G. D. D. (2017). *Pemeriksaan Organoleptis Dan PH (Keasaman) Sebagai Syarat Mutu Keamanan Ikan Tuna (Thunnus SP).* [https://simdos.unud.ac.id/uploads/file\\_penelitian\\_1\\_dir/19bd34bb17006007e3cc5c572bf4e14b.pdf](https://simdos.unud.ac.id/uploads/file_penelitian_1_dir/19bd34bb17006007e3cc5c572bf4e14b.pdf)
- Sari, R. R., & Haryanto, H. (2016). Penentuan Kualitas Ikan Bandeng Menggunakan Algoritma Naive Bayes Berdasarkan Tekstur Pada Citra. *Psi Udinus.*

- Sengar, N., Dutta, M. K., & Sarkar, B. (2017). Computer vision based technique for identification of fish quality after pesticide exposure. *International Journal of Food Properties*, 20(2), 2192–2206. <https://doi.org/10.1080/10942912.2017.1368553>
- Shao, Y., He, Y., Bao, Y., & Mao, J. (2009). Near-infrared spectroscopy for classification of oranges and prediction of the sugar content. *International Journal of Food Properties*, 12(3). <https://doi.org/10.1080/10942910801992991>
- Shari, M. A. M., Buniyamin, N., Halim, M. H. A., Sam, R., & Mohamad, Z. (2013). Enhancement of an infrared based fat measurement sensor. *2013 IEEE International Conference on Smart Instrumentation, Measurement and Applications, ICSIMA 2013*. <https://doi.org/10.1109/ICSIMA.2013.6717973>
- Sholihin, M. (2021). Identifikasi Kesegaran Ikan Berdasarkan Citra Insang dengan Metode Convolution Neural Network. *JATISI (Jurnal Teknik Informatika Dan Sistem Informasi)*, 8(3). <https://doi.org/10.35957/jatisi.v8i3.939>
- ShowRange. (n.d.). *MQ series Semiconductor Gas Sensor*. China Total. Retrieved September 21, 2021, from <http://china-total.com/Product/meter/gas-sensor/Gas-sensor.htm>
- Siddiqui, S. A., Salman, A., Malik, M. I., Shafait, F., Mian, A., Shortis, M. R., & Harvey, E. S. (2018). Automatic fish species classification in underwater videos: Exploiting pre-trained deep neural network models to compensate for limited labelled data. *ICES Journal of Marine Science*, 75(1). <https://doi.org/10.1093/icesjms/fsx109>
- Sidik, F., Nurani, T., & Wisudo, S. (2013). Mutu Dan Perdagangan Ikan Tuna Hasil Tangkapan Longline Yang Didaratkan Di Pps Nizam Zachman Jakarta. *Buletin PSP*, 21(2), 274458.
- Simanjuntak, D. H., Lumingas, L. J. L., & Sangari, J. R. R. (2019). Sustainable Potential of Tuna Fishery Around the Waters of North Sulawesi Province Based on Data from the Bitung Ocean Fisheries Port (PPS). *JURNAL PERIKANAN DAN KELAUTAN TROPIS*, 10(1). <https://doi.org/10.35800/jpkt.10.1.2019.25071>
- SNI. (2013). SNI 2729:2013 Ikan Segar. In *Badan Standarisasi Nasional*.
- Sugiyono. (2018). Prof. Dr. Sugiyono. 2018. Metode Penelitian Kuantitatif, Kualitatif, dan R&D. Bandung: Alfabeta. Prof. Dr. Sugiyono. 2018. *Metode Penelitian Kuantitatif, Kualitatif, Dan R&D*. Bandung: Alfabeta., 63.
- Sulistyo, S., & Margiwyatno, M. (2021). Handheld arduino-based near infrared spectrometer for non-destructive quality evaluation of siamese oranges. *IOP Conference Series: Earth and Environmental Science*.
- Sun, J., Zhang, R., Zhang, Y., Liang, Q., Li, G., Yang, N., Xu, P., & Guo, J. (2018). Classifying fish freshness according to the relationship between EIS parameters and spoilage stages. *Journal of Food Engineering*, 219.

<https://doi.org/10.1016/j.jfoodeng.2017.09.011>

- Supriatna, A., Hascaryo, B., Wisudo, S. H., Baskoro, M., & Nikijuluw, V. P. (2014). Model Rantai Nilai Pengembangan Perikanan Tuna, Tongkol, dan Cakalang di Indonesia. *Jurnal Pengolahan Hasil Perikanan Indonesia*, 17(2), 144–155. <https://core.ac.uk/download/pdf/194416300.pdf>
- Suresh, A., Vinayachandran, A., Philip, C., Velloor, J. G., & Pratap, A. (2021). Fresko pisces: Fish freshness identification using deep learning. In *Lecture Notes on Data Engineering and Communications Technologies* (Vol. 59). [https://doi.org/10.1007/978-981-15-9651-3\\_68](https://doi.org/10.1007/978-981-15-9651-3_68)
- Sydney Fish Market Pty Ltd, A. (2015). *Seafood Handling Guidelines*. Sydney Fish Market Pty Ltd, Australia.
- Taheri-Garavand, A., Nasiri, A., Banan, A., & Zhang, Y. D. (2020). Smart deep learning-based approach for non-destructive freshness diagnosis of common carp fish. *Journal of Food Engineering*, 278. <https://doi.org/10.1016/j.jfoodeng.2020.109930>
- Vedaldi, A., & Lenc, K. (2015). MatConvNet: Convolutional neural networks for MATLAB. *MM 2015 - Proceedings of the 2015 ACM Multimedia Conference*. <https://doi.org/10.1145/2733373.2807412>
- Whitworth, M. B., Millar, S. J., & Chau, A. (2010). Food quality assessment by NIR hyperspectral imaging. *Sensing for Agriculture and Food Quality and Safety II*, 7676. <https://doi.org/10.1117/12.852170>
- Wu, L., Pu, H., & Sun, D. W. (2019). Novel techniques for evaluating freshness quality attributes of fish: A review of recent developments. In *Trends in Food Science and Technology* (Vol. 83, pp. 259–273). <https://doi.org/10.1016/j.tifs.2018.12.002>
- Zhang, H., Zhang, S., Chen, Y., Luo, W., Huang, Y., Tao, D., Zhan, B., & Liu, X. (2020). Non-destructive determination of fat and moisture contents in Salmon (*Salmo salar*) fillets using near-infrared hyperspectral imaging coupled with spectral and textural features. *Journal of Food Composition and Analysis*, 92(February), 103567. <https://doi.org/10.1016/j.jfca.2020.103567>
- Zhang, W., Cao, A., Shi, P., & Cai, L. (2021). Rapid evaluation of freshness of largemouth bass under different thawing methods using hyperspectral imaging. *Food Control*, 125. <https://doi.org/10.1016/j.foodcont.2021.108023>