

BAB II

TINJAUAN PUSTAKA

2.1 Penelitian Terdahulu

Terdapat beberapa penelitian terkait identifikasi dan klasifikasi Nematoda dengan menggunakan metode yang beragam.

2.1.1. *Nematode Identification Techniques and Recent Advances* [7]

Penelitian dengan judul “*Nematode Identification Techniques and Recent Advances*” ditulis oleh Mesfin Bogale, Anil Baniya, dan Peter DiGennaro. Penelitian ini membahas kelebihan dan kekurangan metode identifikasi taksa Nematoda. Taksonomi Nematoda dibangun dengan klasifikasi morfologi berdasarkan panjang tubuh, ekor, mulut, ataupun karakteristik fisik lainnya. Metode klasifikasi morfologi dibantu dengan metode *sub-organismal* (berdasarkan DNA dan protein) untuk mengatasi keterbatasan klasifikasi morfologi ketika taksa berbeda memiliki karakteristik morfologis yang serupa. Metode sub-organismal memerlukan peralatan dan keahlian khusus, serta hasil pemrosesan Nematoda (DNA atau protein) harus dibandingkan ke suatu *database* publik seperti GenBank dan NEMBASE.

Dengan implementasi *artificial intelligence (machine learning)* di bidang *image analysis*, klasifikasi morfologi dapat dilakukan tanpa ahli taksonomi ditempat, dan identifikasi dapat dilakukan pada jumlah spesimen yang banyak dengan cepat. Ketersediaan implementasi *machine learning* seperti TensorFlow dan Keras mempermudah akses publik terhadap metode ini. Terdapat metode klasifikasi morfologi lainnya seperti *autofluorescence*, yaitu klasifikasi menggunakan emisi cahaya natural dari suatu spesimen. Beberapa poin penting dari penelitian ini adalah:

- Metode klasifikasi berdasarkan DNA dan Protein memerlukan peralatan dan keahlian yang spesifik

- Metode *machine learning* memerlukan training data yang banyak, namun klasifikasi dapat dilakukan tanpa ahli taksonomi
- Metode *machine learning* dapat diterapkan dengan biaya yang minim dibanding dengan metode lainnya.
- Metode *machine learning* memiliki performa yang menjanjikan, tetapi memiliki kelemahan atas klasifikasi Nematoda dengan morfologi yang mirip antar taksa yang berbeda

2.1.2. *Nematode Identification using Artificial Neural Networks* [8]

Penelitian dengan judul “*Nematode Identification using Artificial Neural Networks*” ditulis oleh Jason Uhlemann, Oisin Cawley, dan Thomais Kakouli-Duarte. Penelitian ini melakukan identifikasi Nematoda berdasarkan morfologi dan tahap perkembangan dari Nematoda (larva L2 infektif dan dewasa) menggunakan *Convolutional Neural Network* (CNN). Model CNN yang digunakan adalah Xception model dengan metode pelatihan yang diubah-ubah. Model Xception dipilih setelah peneliti membandingkan performa dari ~13 arsitektur CNN ketika dilatih untuk tugas klasifikasi tanpa *pretrained*. Kelemahan dari penelitian ini adalah beberapa model dengan keperluan memori yang tinggi (DenseNet, NASNetLarge) tidak dapat diuji, terdapat pelatihan yang berhenti karena kurangnya memori GPU dari peneliti, dan variasi dalam dataset kurang. Poin-poin penting lainnya dari penelitian ini adalah:

- Model Xception dengan metode pelatihan *Fine-Tuning* (model *pretrained* dengan ImageNet dataset) menunjukkan performa paling tinggi, diikuti dengan metode *Random Initialization* dan *Feature Extraction* (tanpa *pretrained* data)
- Model dengan metode pelatihan *Random Initialization* memiliki tingkat *false-positive* tertinggi, diikuti dengan *Fine-Tuning* dan *Feature Extraction*. Jumlah klasifikasi yang salah dapat dikurangi dengan teknik *Label Smoothing*.

2.1.3. *I-Nema: A Biological Image Dataset for Nematode Recognition* [9]

Penelitian dengan judul “*I-Nema: A Biological Image Dataset for Nematode Recognition*” dilakukan oleh Xuequan Lu, Yihao Wang, Sheldon Fung, dan Xue Qing. Permasalahan yang dibahas berupa kurangnya dataset Nematoda yang tersedia di publik dan variasi dataset kurang, serta kurangnya tolok ukur terhadap performa metode *deep learning* dalam klasifikasi Nematoda. Peneliti menyusun dataset Nematoda yang tersedia secara publik dan diberi label secara manual. Peneliti kemudian melakukan pengujian beberapa model *deep learning* dan membandingkan akurasi dari tiap model dengan satu sama lain. Poin penting dari penelitian ini adalah:

- Model *deep learning* ResNet (*pretrained*) memiliki performa klasifikasi tertinggi dari segi akurasi, sekitar 78%.
- Model memiliki akurasi tinggi terhadap spesies dengan jumlah gambar yang lebih banyak pada dataset, menunjukkan pentingnya jumlah data dan variasi nya dalam suatu dataset.

2.1.4. *A CNN Framework Based on Line Annotations for Detecting Nematodes in Microscopic Images* [10]

Penelitian dengan judul “*A CNN Framework Based on Line Annotations for Detecting Nematodes in Microscopic Images*” ditulis oleh Long Chen, et.al. Penelitian merancang sistem untuk mendeteksi keberadaan Nematoda dalam suatu gambar dengan menggunakan CNN dan merepresentasikan objek Nematoda dengan garis melengkung. Performa dari sistem ini sangat akurat untuk Nematoda dewasa. Hasil dari penelitian menunjukkan bahwa proses deteksi Nematoda dewasa pada suatu gambar lebih mudah dilakukan dengan pendekatan yang dirancang dibandingkan dengan metode umumnya. Sistem juga dapat mendeteksi Nematoda dalam kondisi bertumpukkan/bergerombol. Namun, metode ini tidak cocok untuk Nematoda yang tidak dapat direpresentasikan dengan garis, dan mengalami penurunan akurasi pada spesies Nematoda dengan struktur morfologi yang sangat pipih.

2.1.5. *Data Augmentation for Automated Pest Classification in Mango Farms* [11]

Penelitian dengan judul “*Data Augmentation for Automated Pest Classification in Mango Farm*” ditulis oleh Kusrini Kusrini, et.al. Penelitian ini melakukan klasifikasi terhadap hama pada perkebunan mangga dengan CNN dan augmentasi data. Meskipun topik penelitian berupa klasifikasi hama untuk perkebunan, metode pengolahan data dan augmentasi yang dilakukan dapat digunakan di topik lainnya. Augmentasi data yang dilakukan berupa pengaburan gambar, perubahan kontras, transformasi *affine*, dan penambahan noise. Penelitian menunjukkan bahwa dengan proses augmentasi data yang baik, akurasi dari CNN dapat ditingkatkan, terutama pada kelas yang memiliki dataset yang kurang. Namun proses augmentasi menambah waktu training yang proporsional dengan data yang ditambahkan. Kemudian tipe augmentasi yang dilakukan tidak boleh sembarang, karena ditemukan augmentasi dengan penambahan *blur* dan *noise* menurunkan akurasi, serta perubahan kontras tidak mengubah akurasi dari model. Akurasi model meningkat karena augmentasi data dengan proses translasi dan rotasi.

Berikut rangkuman singkat dari penelitian terdahulu yang berdampak dalam penyusunan dan pelaksanaan penelitian ini.

Tabel 2.1 Rangkuman penelitian terdahulu yang berdampak pada penelitian

Judul Penelitian (Tahun)	Poin yang Berdampak pada Penelitian
<i>Nematode Identification Techniques and Recent Advances</i> (2020)	<ul style="list-style-type: none">Setelah mempertimbangkan kelebihan dan kekurangan tiap metode, kemampuan peneliti, ketersediaan peralatan, serta kondisi di Indonesia, metode klasifikasi <i>deep learning</i> paling memungkinkan untuk diterapkan dalam sistem klasifikasi.

<p><i>Nematode Identification using Artificial Neural Networks (2019)</i></p>	<ul style="list-style-type: none"> • Model dengan <i>pretrained weight</i> menghasilkan performa yang menjanjikan dalam permasalahan klasifikasi nematoda
<p><i>I-Nema: A Biological Image Dataset for Nematode Recognition (2021)</i></p>	<ul style="list-style-type: none"> • Mendapatkan dataset nematoda berupa 2769 sampel dengan 19 kelas klasifikasi • Model <i>deep learning</i> ResNet (<i>pretrained</i>) memiliki performa tinggi dalam klasifikasi nematoda • Menunjukkan pentingnya jumlah dan variasi data, mendukung penerapan augmentasi data.
<p><i>A CNN Framework Based on Line Annotations for Detecting Nematodes in Microscopic Images (2020)</i></p>	<ul style="list-style-type: none"> • Metode klasifikasi dengan anotasi garis melengkung memiliki performa tinggi tetapi hanya pada sampel yang dapat direpresentasikan dengan satu garis saja. • Tidak cocok untuk beberapa spesies yang sering ditemukan di Indonesia
<p><i>Data Augmentation for Automated Pest Classification in Mango Farms (2020)</i></p>	<ul style="list-style-type: none"> • Mendukung penerapan augmentasi data dalam bidang klasifikasi hama pada tanaman • Menunjukkan peningkatan performa yang menjanjikan dalam penggunaan augmentasi data tertentu pada model CNN.

2.2 Tinjauan Teori

2.2.1 Convolutional Neural Network (CNN)

CNN adalah salah satu jenis *Neural Network* yang umum digunakan di dunia *computer vision*. CNN terdiri dari neuron yang tersambung dengan satu sama lain, menyerupai struktur dari *Multi-Layer Perceptron (MLP)*. Tiap neuron dan sambungan antar neuron memiliki berat, bias, dan *activation function*. Struktur dari CNN terinspirasi oleh struktur natural neuron pada otak hewan. CNN bekerja

dengan melakukan konvolusi 2 dimensi menggunakan kernel konvolusi ke suatu gambar. CNN tidak memerlukan banyak pemrosesan dataset dibanding algoritma lainnya. *Feature extraction* dilakukan secara otomatis, tidak perlu didefinisikan sebelum melatih *Neural Network*. Kemampuan CNN dalam melakukan *feature extraction* menghasilkan kemampuan klasifikasi yang tinggi.

2.2.1.1 Residual Networks (ResNet)

Salah satu model CNN yang memiliki performa tinggi dalam klasifikasi adalah ResNet. ResNet berupa pengembangan model CNN berdasarkan arsitektur VGG yang menerapkan block bernama *residual blocks*. Blok ini mengatasi masalah ketika pelatihan model CNN dengan jumlah layer yang banyak mencapai saturasi performa dan memakan waktu pelatihan yang tinggi. *Residual blocks* berupa blok CNN yang beberapa layernya terhubung secara langsung dan melompati layer didepannya. Koneksi yang lompat antar layer ini mengatasi masalah *vanishing gradient* dalam pelatihan CNN. Terdapat beberapa variasi model ResNet berdasarkan jumlah layer pada model, yaitu ResNet-50, ResNet-101, dan ResNet-152. Model dengan layer (dan parameter) yang lebih banyak memiliki performa lebih baik dibandingkan dengan variasi lainnya [12].

Lalu, dikembangkan derivasi ResNet baru dengan mengubah cara propagasi data pada tiap *residual block* menggunakan fungsi identitas sebagai koneksi yang melompati layer, untuk propagasi data kedepan maupun kebelakang. Fungsi identitas juga digunakan pada beberapa fungsi aktivasi, mengubah fungsi aktivasi menjadi “*pre-activation*” untuk *weight layers*, menghasilkan *residual block* baru. Derivasi ResNet dengan *residual block* ini disebut dengan ResNetV2. Variasi ini memiliki kemampuan optimisasi *loss* yang lebih mudah dan cepat, serta menurunkan *overfitting* pada model [13].

2.2.1.2 EfficientNet

Model CNN umum dikembangkan dengan penggunaan *resource* (komputasi dan memori) terbatas dan jika *resource* tersedia, model diperbesar dengan metode pengulangan *block* pada layer tertentu. Pada penelitian oleh Mingxing Tan dan Quoc V. Le, dikemukakan metode peningkatan kapasitas model baru, yaitu mengubah skala lebar, dalam, dan resolusi dari model dengan suatu

koefisien gabungan [14]. Berdasarkan observasi ini, Neural Architecture Search (NAS) [15] digunakan untuk mendesain model keluarga baru yang disebut EfficientNet. Salah satu variasi EfficientNet (EfficientNet-B7) mencapai performa *state-of-the-art* pada ImageNet dataset dengan ukuran model yang jauh lebih kecil dari model lainnya. Kecepatan inferensi juga jauh lebih cepat. Model ini menggunakan *convolution block* bernama *MBConv* [14].

EfficientNet kemudian dikembangkan lebih lanjut dengan menggunakan NAS yang memaksimalkan kecepatan pelatihan dan efisiensi dari parameter, serta menggunakan *convolution block* baru bernama *Fused-MBConv* yang meningkatkan kecepatan pelatihan dan ukuran model makin kecil dibandingkan sebelumnya. Kombinasi jenis *convolution block* antar *MBConv* dan *Fused-MBConv* ditemukan menggunakan NAS untuk optimisasi ukuran model dan kecepatan pelatihan. Variasi ini disebut dengan nama EfficientNetV2. Dengan metode pelatihan tertentu, varian model ini 5x – 11x lebih cepat dilatih dibanding dengan model lainnya, dengan parameter lebih sedikit, hingga 6x [16].

2.2.2 Transformer Deep Learning

Model *transformer* adalah model *deep learning* yang mengadopsi mekanisme *self-attention*. Mekanisme ini meningkatkan efek dari bagian input data tertentu dan mengurangi efek dari bagian lainnya. Dalam *deep learning*, mekanisme *self-attention* berarti membedakan bias dan *weight* dari tiap input data. Model ini umum digunakan dalam permasalahan *Natural Language Processing* dan *Computer Vision*. Arsitektur dari model *transformer* terdiri dari komponen *encoder* dan *decoder*. *Encoder* adalah layer-layer yang memproses data input secara satu per satu dari layer ke layer, menghasilkan informasi mengenai bagian input mana yang relevan dengan input lainnya. *Decoder* adalah layer-layer yang membaca output dari *Encoder* dan menghasilkan suatu output berdasarkan relasi dari tiap bagian input.

2.2.2.1 CoAtNet

Model *Vision Transformer* (ViT) [17] dengan *pre-training* pada dataset JFT-300M [18] menunjukkan performa yang sebanding dengan model *state-of-the-art* CNN, mengindikasikan bahwa model *transformer* memiliki potensi kapasitas

model yang lebih tinggi dibanding model CNN. Namun, model *transformer* memiliki tingkat generalisasi yang buruk. Untuk mengatasi masalah generalisasi, model CoAtNet menggabungkan arsitektur CNN dengan *transformer* untuk menghasilkan *building block* baru dan mencapai performa *state-of-the-art*. Model baru ini memiliki kemampuan generalisasi dari CNN dan skalabilitas tinggi dari *transformers*.

Struktur CoAtNet terdiri dari lima layer utama, yaitu satu layer konvolusi, dua layer MBConv, dan dua layer *Transformer*. Terdapat berbagai macam variasi CoAtNet, bergantung pada jumlah pengulangan *block* pada tiap layer dan jumlah kanal keluaran dari *block* tersebut. Variasi model CoAtNet terdiri dari 5 variasi dasar (CoAtNet-0 sampai dengan CoAtNet-4) dan 3 variasi dengan parameter *block* yang berbeda (CoAtNet-5 sampai CoAtNet-7) [19].

2.2.3 Augmentasi Data

Augmentasi data adalah teknik-teknik yang digunakan untuk meningkatkan data yang ada dengan menambahkan data yang sudah dimodifikasi atau dibuat secara sintesis berdasarkan data yang ada. Teknik yang umum digunakan untuk augmentasi adalah rotasi, translasi, membalik gambar, penambahan *noise*, *artificial intelligence*, dan metode lainnya. Augmentasi berguna untuk menggeneralisasi dataset dan mencegah overfitting. Penelitian oleh Dr. Kusriani [11] menunjukkan proses augmentasi data membantu meningkatkan akurasi dari model *deep learning* dalam klasifikasi hama pada perkebunan mangga.

2.2.3.1 Generative Adversarial Network (GAN)

Salah satu metode augmentasi data menggunakan *artificial intelligence* adalah menghasilkan gambar menggunakan model Generative Adversarial Network (GAN). GAN adalah model *machine learning* yang memiliki dua komponen, yaitu Generator dan Discriminator. Komponen Generator bertujuan untuk menghasilkan data yang tidak dapat dibedakan dari dataset yang dilatih, sedangkan komponen Discriminator harus dapat menebak apakah input dari dataset atau input berupa input palsu [20]. Penggunaan GAN untuk proses augmentasi data sangat menjanjikan karena kemampuan GAN untuk mensintesis gambar yang baru, berdasarkan pola yang ada pada dataset.

Salah satu variasi implementasi GAN yang cocok untuk *supervised learning* adalah RumiGAN. RumiGAN berupa *framework* untuk melatih Generator dan Discriminator dengan menyediakan data positif (data yang harus dipelajari) dan data negatif (data yang harus dihindari dalam pelatihan). Metode pelatihan *supervised* GAN ini berasal dari filosofi penyair bernama Rumi dari Persia, seni dari mengerti sesuatu berarti mengerti hal yang harus diabaikan. Formulasi ini memungkinkan komponen Discriminator untuk merepresentasikan target pembelajaran lebih baik dengan memberi penalti ketika komponen Generator mempelajari hal yang harus diabaikan. Hal ini memungkinkan GAN untuk mempelajari kelas spesifik dalam suatu dataset dengan menetapkan kelas yang diinginkan sebagai dataset positif dan menetapkan kelas lainnya sebagai dataset negatif. RumiGAN juga dapat digunakan untuk mengatasi bias dataset ketika jumlah data pada tiap kelas di dataset tidak seimbang [21]. *Framework* ini dapat diterapkan pada berbagai macam jenis GAN, yaitu Auxiliary Classifier GAN (ACGAN) [22], Standard GAN (SGAN) [23], dan Least Square GAN (LSGAN) [24][21].




2.2.4 Karakteristik Nematoda

Nematoda adalah kelompok mikroorganisme cacing yang dapat tinggal di berbagai macam ekosistem, dan memiliki klasifikasi filum tersendiri. Bentuk Nematoda yang umum ditemukan berupa bilateral simetris, bulat, atau berbentuk silinder. Ukuran dari tiap spesimen juga bervariasi, mulai dari beberapa millimeter sampai dengan 1 meter [6], dengan Genus Nematoda yang menjadi parasit pada tanaman memiliki ukuran yang relatif kecil (0.1mm ~ 4mm) [5] dan memerlukan mikroskop. Nematoda pada tanaman dapat hidup di semua bagian dari tumbuhan dan dapat menular ke tanaman lain melalui kontak langsung antar tanaman dan terbawa organisme lain (seperti manusia dan hewan) [6].

Beberapa jenis Nematoda parasit tanaman yang sering ditemukan di Indonesia memiliki fitur diskriminatif pada morfologi dari tiap Genus Nematoda yang di klasifikasi. Berikut penjelasan singkat terhadap Genus Nematoda yang akan diteliti dalam penelitian ini. Sumber informasi karakteristik morfologi didapatkan dari

observasi pada spesimen yang didapat, penemuan oleh penelitian terdahulu, serta data yang tersedia secara publik [6][25][26][27].

Tabel 2.2 Karakteristik Morfologis Nematoda. Sumber: berbagai sumber [6][9][25][26][27]

Genus Classification	Common Characteristics	Male Dimorphism	Female Dimorphism
Genus Acrobeles ([9]) 	Kutikula ¹ dengan ornament seolah terbagi menjadi blok-blok terpisah. Bibir berbentuk segitiga. Ekor relatif pendek		Satu gonad
Genus Acrobeloides ([9]) 	Bibir dengan probolae yang unik. Cheilostom ² yang lebar pada posterior yang sempit		
Genus Amplimerlinius ([9]) 	Kutikula tebal pada ujung ekor. Stilet ³ dengan <i>basal knob</i> ⁴ . Memiliki 6 garis <i>lateral lines</i> ⁵	Spikula ⁶ tumpul tanpa membrane	Ekor lebih tumpul

¹ Kutikula: Lapisan kulit eksternal pada tubuh Nematoda


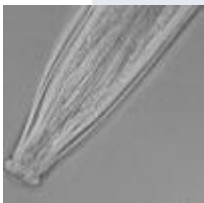


² Cheilostom: Bukaan pada organ pencernaan

³ Stilet: Lubang mulut berbentuk jarum atau tombak



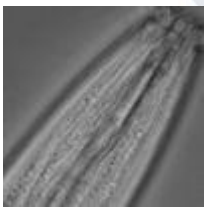
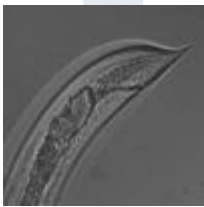
⁴ Knobs: Benjolan pada dasar stilet Nematoda dengan berbagai macam bentuk

⁵ Lateral Lines: Organ deteksi vibrasi dan tekanan, berbentuk garis sepanjang tubuh

⁶ Spikula (Nematoda): Organ reproduksi jantan berbentuk seperti duri





<p>Genus Aphelenchoides ([9])</p> 	<p>Metacarpus⁷ besar, stilet pipih dengan <i>basal knob</i> yang terkadang tidak tampak.</p>	<p>Spikula yang melengkung dan runcing</p>	
<p>Genus Aporcelaimus ([9])</p> 	<p>4mm – 10mm. Kutikula tebal. Bibir tebal dan menyatu. Ekor pendek dan tumpul.</p>		<p>Dua ovarium. Vulva dengan celah melintang</p>
<p>Genus Axonchium ([9])</p> 	<p>1mm – 3.7mm. Kutikula halus. Esofagus panjang dan pipih. Bagian anterior dan posterior terpisah dengan jelas. Ekor bulat.</p>		<p>Satu ovarium.</p>
<p>Genus Criconema</p> 	<p>Tubuh dengan garis parallel, membentuk tumpukkan cincin. Kutikula dengan ornament seperti duri atau sisik pada tubuh.</p>	<p>Tidak memiliki stilet, jumlah sedikit dibanding betina, serta memiliki 2-4 garis pada lateral lines</p>	<p>Stilet panjang, serta ekor berbentuk kerucut atau bulat tumpul</p>





⁷ Metacarpus: Bagian utama organ Esofagus, berupa organ pencernaan Nematoda, umum berbentuk lingkaran dan berotot

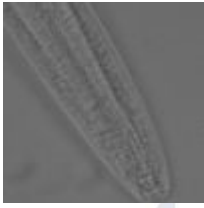


<p>Genus Criconemoides</p> 	<p>Karakteristik tubuh seperti Genus Criconema.</p>	<p>Tanpa stilet, memiliki 4 lateral lines, langka,</p>	<p>Stilet panjang dengan anchor knobs (berbentuk jangkar).</p>
<p>Genus Ditylenchus ([9])</p> 	<p>Stilet pendek.</p>	<p>Memiliki caudal alae⁸ yang tidak sampai bagian ekor. Ekor lancip</p>	<p>4 garis pada lateral lines. Ekor tumpul.</p>
<p>Genus Dorylaimus ([9])</p> 	<p>2mm – 9mm. Kutikula tebal. Odontostyle yang kuat.</p>	<p>Ekor pendek dan tumpul.</p>	<p>Dua ovarium. Ekor panjang dan lancip</p>
<p>Genus Eudorylaimus ([9])</p> 	<p>0.8mm – 3.5mm. Kutikula halus. Bibir terpisah. Memiliki odontostyle⁹ panjang.</p>		<p>Dua ovarium.</p>


⁸ Caudal alae: ekstensi dari kutikula pada Nematoda, umum menyelubungi kloaka pada Nematoda jantan

⁹ Odontostyle: organ yang digunakan untuk menangkap makanan, berbentuk tombak yang dapat menonjol

<p>Genus Helicotylenchus</p> 	<p>Tubuh berbentuk spiral. Stilet berukuran normal.</p>	<p>Memiliki bagian kepala (anterior) yang lebih kecil dibanding betina</p>	
<p>Genus Hemicycliophora</p> 	<p>Umum memiliki “sarung”, lapisan tambahan pada tiap tahap kehidupan</p>	<p>Spikula melengkung (berbentuk “U” atau kait). Caudal alae melapisi kurang dari 1/3 bagian ekor</p>	<p>Lapisan kutikula lebih tebal. Ekor lebih pendek.</p>
<p>Genus Hirschmanniella</p> 	<p>0.9mm – 4.2mm. Tubuh pipih. Serupa dengan Genus Radopholus. Bibir tumpul dan rata.</p>	<p>Caudal alae tidak menyelubungi ekor.</p>	<p>Saluran kelamin dengan dua cabang.</p>
<p>Genus Hoplolaimus</p> 	<p>1mm – 1.5mm. Tubuh cenderung lurus. Kepala berbentuk trapezoid. Bibir lebar dan rata. 4 atau kurang garis lateral lines. Stilet besar dengan anchor knobs.</p>	<p>Caudal alae menyelubungi ekor. Struktur esofagus lebih kecil.</p>	<p>Saluran kelamin dengan dua cabang.</p>

<p>Genus Meloidogyne</p> 	<p>Bentuk tubuh bergantung dengan jenis kelamin spesimen</p>	<p>Tubuh pipih dengan kepala berkerangka keras. Tanpa stilet</p>	<p>Tubuh berbentuk buah pir dengan kepala lunak. Stilet pipih dengan rounded knobs. Dua ovarium.</p>
<p>Genus Mesodorylaimus</p> 	<p>0.8mm – 2.3mm. Kutikula halus. Memiliki odontostyle.</p>	<p>Jumlah lebih sedikit.</p>	<p>Dua ovarium. Vulva dengan celah melintang.</p>
<p>Genus Miconchus ([9])</p> 	<p><i>Dorsal tooth</i> yang besar dan dua <i>subventral teeth</i>. Ekor memanjang.</p>		
<p>Genus Mylonchulus ([9])</p> 	<p>0.5mm – 3.2mm. Ekor bervariasi antar spesies (tumpul atau memanjang) Bibir tumpul dan rata.</p>	<p>Spikula pendek. Jumlah lebih banyak.</p>	<p>Dua ovarium.</p>
<p>Genus Panagrolaimus</p>	<p>Ekor lancip dan tidak simetris. Bibir sedikit terpisah.</p>	<p>Spikula dua segmen, terpisah pada bagian ujung</p>	<p>Satu ovarium.</p>

([9]) 		organ. Tidak memiliki caudal alae.	
Genus Pratylenchus ([9]) 	Tubuh pipih. Tidak memiliki deirid (organ sentuh, umum terletak pada daerah serviks lateral), bibir mulut rendah dan rata.	Memiliki <i>caudal alae</i> (tonjolan pelindung cloaca) menyelubungi ekor.	Tubuh lebih pipih/ramping dibanding jantan
Genus Pristionchus ([9]) 	Bentuk mulut berubah seiring perkembangan (panjang pipih dengan gigi kecil, dan pendek lebar dengan dua gigi besar)		Dua ovarium.
Genus Radopholus 	Tubuh pipih.	Memiliki bibir mulut tinggi dan tumpul, stilet kecil dengan <i>basal knob</i> yang kecil,	Memiliki bibir mulut rendah, tanpa stilet, tanpa deirid, ekor panjang dan lancip

<p>Genus Rhabditis ([9])</p> 	<p>Kutikula tipis. Bentuk tubuh bervariasi antar spesies. Ekor umum panjang.</p>		
<p>Genus Trichodorus</p> 	<p>Tubuh pipih yang bulat di bagian depan dan belakang (<i>anterior & posterior</i>), dengan stilet yang tipis. Memiliki kutikula yang tebal</p>		
<p>Genus Xiphinema</p> 	<p>1.5mm – 5.0mm. Stilet sangat panjang</p>		

UMMN

UNIVERSITAS
MULTIMEDIA
NUSANTARA