

BAB II

TINJAUAN PUSTAKA

2.1 Penelitian Terdahulu

Berbagai penelitian terdahulu yang telah mengkaji dan mengembangkan beragam pendekatan dalam bidang pengolahan citra medis guna meningkatkan akurasi dan ketepatan dalam membedakan lesi kulit. Pendekatan tersebut mencakup pemanfaatan algoritma *deep learning*, teknik augmentasi, serta strategi klasifikasi berbasis fitur visual. Sebagai landasan konseptual dan berhubungan untuk penelitian ini, sejumlah studi-studi yang relevan dengan deteksi kanker kulit ditampilkan pada Tabel 2.1.

Tabel 2. 1 Penelitian Terdahulu

Artikel	Masalah	Metode	Hasil
[17]	Klasifikasi kanker kulit menggunakan citra <i>dermatoskopi</i> dengan tantangan membedakan lesi jinak dan ganas	<i>Vision Transformer</i> (ViT) dengan pendekatan <i>multi-scale attention</i> dan ensemble learning	Akurasi 95.05% pada dataset ISIC2018. Teknik ini menunjukkan peningkatan performa dibandingkan model tunggal.
[27]	Diagnosis melanoma kulit menggunakan gambar dermoskopi dengan akurasi dan presisi tinggi	Gabungan U-Net, <i>Inception-ResNet-v2</i> , dan <i>Vision Transformer</i>	Akurasi 98.65%, sensitivitas 99.20%, spesififikasi 98.03%, lebih baik dibandingkan dengan pendekatan lain dalam diagnosis kanker kulit.
[19]	Deteksi penyakit kulit dengan akurasi yang tinggi pada dataset HAM10000 dan ISIC, tantangan pada dataset yang tidak seimbang	<i>Vision Transformer</i> (ViT), CNN, <i>Xception</i> , dan <i>Explainable AI (Grad-CAM visualizations)</i>	Akurasi 96.74%, precision 95.46%, recall 96.27%, specificity 96.00%, F1-Score 95.86% pada dataset HAM10000, dan akurasi 93.19% pada dataset ISIC.
[21]	Deteksi lesi kulit dengan menggabungkan gambar <i>dermoskopi</i> , klinis, dan MRI untuk meningkatkan akurasi diagnosis.	<i>Vision Transformer</i> (ViT), <i>transfer learning</i> , dan mekanisme perhatian saluran (<i>channel attention</i>)	Akurasi 99%, sensitivitas, spesififikasi, dan presisi yang lebih tinggi dibandingkan dengan teknik tradisional.

Artikel Jurnal	Masalah	Metode	Hasil
[23]	Deteksi melanoma pada citra <i>dermoskopik</i> yang akurasi nya masih rendah dengan metode <i>deep learning</i> tunggal.	<i>EfficientNetV2S</i> dan <i>Swin-Transformer</i> .	Akurasi 99.10%, sensitivitas 99.27%, spesifisitas 99.80%
[21]	Deteksi lesi kulit dengan multimodal data, menggunakan data citra <i>dermoskopi, ultrasound, dan MRI</i>	<i>Transfer learning, channel attention, dan Vision Transformer (ViT)</i> untuk analisis multimodal	Akurasi 99%, menunjukkan peningkatan signifikan dibandingkan dengan metode sebelumnya.
[28]	Deteksi kanker kulit multi-faktor dengan dataset HAM10000 yang tidak seimbang	<i>Deep sequential CNN</i> untuk mendeteksi lesi kulit dan meningkatkan <i>visualisasi</i> menggunakan alat berbasis web	Akurasi 96.25%, lebih baik dari model CNN <i>transfer learning</i> dan <i>ResNet-50</i> , serta menunjukkan peningkatan signifikan dalam klasifikasi lesi kulit.
[22]	Klasifikasi <i>multiclass</i> lesi kulit dengan dataset yang tidak seimbang	<i>Separable Vision Transformer (SVT)</i> , menggunakan data <i>augmentation</i> dan <i>preprocessing</i> untuk mengatasi masalah ketidakseimbangan kelas	Akurasi 95.6%, sensitivitas 96.7%, spesifisitas 95%, AUC 0.95 pada dataset HAM10000, ISBI-2017, dan ISIC
[29]	Segmentasi lesi kulit dengan tantangan deteksi batas lesi yang kabur dan tidak jelas pada dataset medis kecil	<i>Hybrid model CNN dan Transformer (ViT)</i> dengan <i>SpatialGroupAttention (SGA)</i> dan <i>Focus module</i> untuk meningkatkan pemrosesan gambar	Akurasi 93.90%, <i>IoU</i> 78.28%, <i>Dice</i> 86.32%, sensitivitas 86.18%, spesifisitas 97.56% pada dataset ISIC 2017. Melampaui banyak model tradisional dan memberikan akurasi lebih tinggi dalam segmentasi batas lesi.
[24]	Klasifikasi <i>multiclass</i> lesi kulit dengan tantangan data tidak seimbang, membutuhkan model efisien untuk pemrosesan gambar	<i>SkinSwinViT</i> , berbasis <i>Swin Transformer</i> dengan mekanisme perhatian lokal-global, menggunakan teknik <i>augmentasi</i> data untuk menangani ketidakseimbangan data	Akurasi 97.88%, <i>recall</i> 97.75%, <i>precision</i> 97.83%, <i>specificity</i> 99.36%, F1-score 97.79% pada dataset ISIC2018. Model ini menunjukkan hasil yang lebih baik dibandingkan dengan <i>SwinViT</i> dan model lainnya.

Tabel 2.1, menampilkan berbagai penelitian sebelumnya menunjukkan bahwa penggunaan teknologi *deep learning*, khususnya arsitektur *Vision Transformer* (ViT), memberikan kemajuan yang signifikan dalam klasifikasi dan segmentasi kanker kulit berbasis citra. Pendekatan yang menggabungkan ViT dengan teknik *multi-scale attention* serta *ensemble learning* terbukti mampu meningkatkan akurasi klasifikasi lesi jinak dan ganas secara signifikan, mencapai 95.05% pada dataset ISIC2018 [17]. Metode *ensemble* ini dinilai lebih efektif dibandingkan dengan penggunaan model tunggal karena mampu mengoptimalkan hasil prediksi dari berbagai skala representasi fitur. Penggabungan beberapa arsitektur *deep learning* juga dilakukan dalam upaya meningkatkan performa diagnosis melanoma. Salah satu penelitian mengintegrasikan *U-Net* untuk segmentasi, *Inception-ResNet-v2* untuk ekstraksi fitur mendalam, dan ViT sebagai model klasifikasi, menghasilkan akurasi mencapai 98.65%, sensitivitas 99.20%, serta spesifisitas 98.03% [27]. Hasil tersebut menunjukkan keunggulan pendekatan *hybrid* dalam menghasilkan diagnosis yang lebih akurat dan handal. Selain itu, pendekatan lain yang memadukan ViT dengan CNN dan *Xception*, disertai penerapan *Explainable AI* melalui visualisasi *Grad-CAM*, berhasil mencapai akurasi sebesar 96.74% pada dataset *HAM10000* dan 93.19% pada dataset ISIC [19]. Metode ini tidak hanya unggul dari sisi performa, tetapi juga mampu memberikan interpretabilitas yang lebih baik terhadap hasil klasifikasi.

Penelitian lain memanfaatkan analisis *multimodal* dengan menggabungkan data dari citra dermatoskopi, citra klinis, dan pencitraan MRI. Pendekatan ini dikembangkan melalui *transfer learning* dan mekanisme *channel attention* berbasis ViT, yang terbukti mampu mencapai akurasi hingga 99% [21]. Integrasi data dari berbagai sumber tersebut memperkaya informasi fitur yang dianalisis oleh model dan meningkatkan akurasi diagnosis secara signifikan dibandingkan metode konvensional yang hanya menggunakan satu jenis citra. Untuk permasalahan akurasi deteksi melanoma yang masih rendah, dapat mengembangkan model *ensemble* yang menggabungkan *EfficientNetV2S* dan *Swin-Transformer* untuk mendeteksi kanker kulit. Dengan menggunakan dataset *HAM-10000*, berhasil

meningkatkan akurasi klasifikasi menjadi 99.10%, dengan sensitivitas 99.27% dan spesifisitas 99.80% [23].

Masalah ketidakseimbangan kelas pada dataset medis juga menjadi perhatian dalam beberapa penelitian. Salah satu studi menggunakan *Separable Vision Transformer* (SVT) yang dikombinasikan dengan *data augmentation* dan *preprocessing* untuk menangani ketidakseimbangan kelas. Pendekatan ini mampu mencapai akurasi sebesar 95.6%, sensitivitas 96.7%, spesifisitas 95%, dan AUC 0.95 pada dataset HAM10000, ISBI-2017, dan ISIC [22]. Hal ini menunjukkan bahwa pemilihan arsitektur yang ringan namun efektif, dikombinasikan dengan teknik penyeimbangan data, dapat memberikan hasil klasifikasi multiclass yang memadai. Selanjutnya, pendekatan *hybrid* lain yang memadukan CNN dan *Transformer* dengan tambahan modul *Spatial Group Attention* (SGA) dan *Focus module* dikembangkan untuk meningkatkan segmentasi lesi pada dataset medis berukuran kecil. Model ini berhasil mencapai akurasi 93.90%, nilai *Intersection over Union* (IoU) sebesar 78.28%, dan *Dice coefficient* sebesar 86.32%, dengan sensitivitas 86.18% serta spesifisitas 97.56% [29]. Hasil tersebut menunjukkan bahwa model ini mampu mengatasi keterbatasan data sekaligus menghasilkan segmentasi batas lesi dengan presisi tinggi.

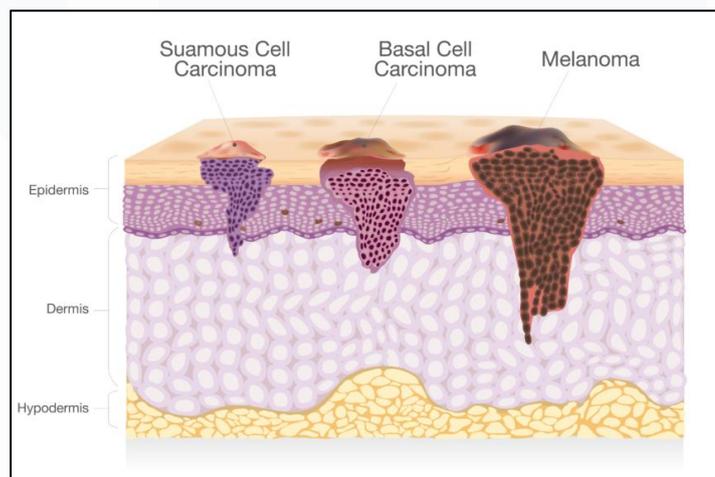
Terakhir, pendekatan berbasis *SkinSwinViT*—yang menggunakan mekanisme perhatian lokal dan global dari Swin Transformer serta teknik augmentasi data untuk mengatasi ketidakseimbangan—mampu memberikan performa klasifikasi *multiclass* yang unggul. Dengan akurasi mencapai 97.88%, *recall* 97.75%, *precision* 97.83%, spesifisitas 99.36%, dan *F1-score* 97.79% pada dataset ISIC2018 [24], model ini menunjukkan kemampuan generalisasi yang sangat baik. Secara keseluruhan, temuan dari penelitian-penelitian terdahulu memperlihatkan bahwa integrasi arsitektur ViT dengan berbagai metode pelengkap, baik melalui pendekatan hybrid, multimodal, maupun augmentasi data, mampu menghasilkan model klasifikasi dan segmentasi kanker kulit yang akurat, adaptif, serta memiliki interpretabilitas yang tinggi. Secara keseluruhan, meskipun Vision Transformer (ViT) masih menjadi pilihan utama dalam deteksi kanker kulit,

eksplorasi model-model lain seperti Swin Transformer dapat menunjukkan pentingnya Transformer serta teknik-teknik lanjutan lainnya dalam meningkatkan akurasi dan kemampuan generalization sistem deteksi kanker kulit otomatis.

2.2 Tinjauan Teori

2.2.1 Kanker Kulit

Kanker kulit merupakan penyakit yang terjadi akibat perubahan sifat sel kulit yang awalnya normal menjadi ganas, sehingga sel-sel tersebut berkembang biak secara tidak terkendali dan menyebabkan kerusakan pada DNA [30]. Kanker kulit terbagi menjadi dua jenis utama, yaitu melanoma dan kanker kulit nonmelanoma. Gambar tipe-tipe kanker kulit ditampilkan pada Gambar 2.1.

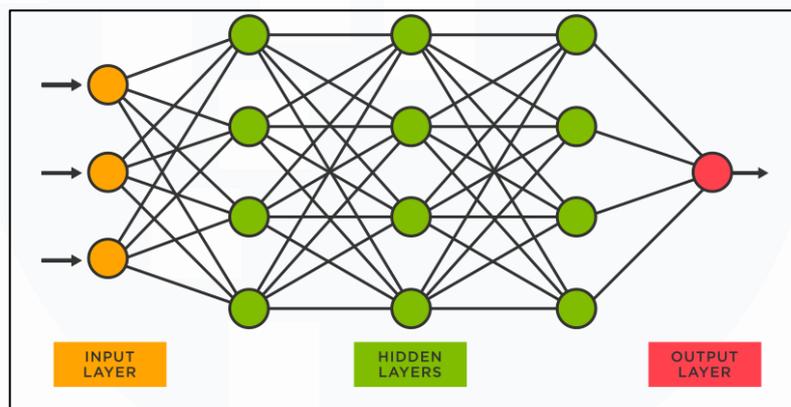


Gambar 2. 1 Tipe-Tipe Kanker Kulit [31]

Gambar 2.1 menampilkan gambar kanker kulit nonmelanoma, seperti karsinoma sel basal dan karsinoma sel skuamosa [32], serta gambar melanoma. Diantara keduanya, melanoma memiliki tingkat keganasan yang jauh lebih tinggi. Melanoma merupakan jenis kanker kulit yang paling berbahaya. Jika menyebar ke bagian tubuh lain (metastasis), tingkat kelangsungan hidup penderitanya cenderung rendah [33]. Selain itu, kanker kulit termasuk dalam tiga besar jenis kanker yang umum ditemukan di Indonesia selain kanker serviks dan kanker payudara. Lebih dari 3,5 juta kasus kanker kulit tercatat di Amerika Serikat, menjadikannya jenis kanker paling banyak di negara tersebut [30].

2.2.2 Deep Learning

Deep Learning merupakan salah satu cabang dari *Machine Learning* yang algoritmanya dikembangkan berdasarkan inspirasi dari cara kerja otak manusia [12]. *Deep learning* memiliki kemampuan untuk membangun pemahamannya secara mandiri melalui proses komputasi internal [34]. Teknologi ini dirancang untuk terus memproses dan mengevaluasi data secara berkelanjutan. *Deep neural network* di tampilkan pada Gambar 2.2.



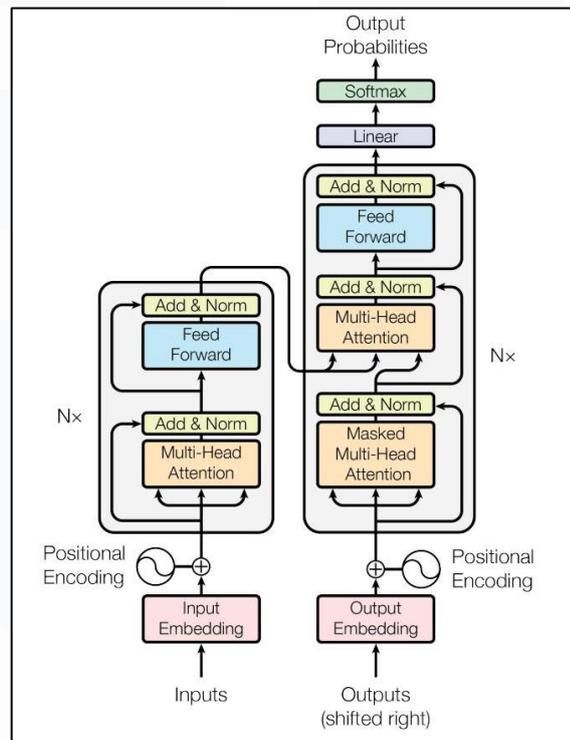
Gambar 2. 2 Deep Learning Network [35]

Gambar 2.2 menunjukkan ilustrasi arsitektur dasar dari *deep learning*, khususnya jaringan saraf berlapis (*deep neural network*). Model ini terdiri atas satu lapisan *input*, beberapa lapisan tersembunyi (*hidden layers*), dan satu lapisan *output*. Dengan menggunakan pembelajaran yang mampu membentuk representasi data dalam berbagai level kompleksitas. Melalui susunan modul-modul berlapis, metode ini secara bertahap mentransformasikan data dari bentuk awal menjadi representasi yang lebih tinggi dan abstrak, sehingga memungkinkan pendeteksian pola-pola tersembunyi dalam data [36].

2.2.3 Transformer

Salah satu algoritma *deep learning* yang banyak digunakan dalam pemrosesan data berurutan adalah *Transformer*, yang diperkenalkan oleh Ashish Vaswani dkk. melalui penelitian berjudul “*Attention is All You Need*” [13]. Algoritma ini menggunakan mekanisme *self-attention* dalam arsitekturnya dan dirancang untuk memproses data secara efisien dalam bentuk urutan [14]. Dengan

struktur *encoder-decoder*, *Transformer* mampu melakukan prediksi kata secara berurutan serta mentransformasikan satu urutan menjadi urutan lainnya. Gambar model arsitektur *transformer* ditampilkan pada Gambar 2.3.



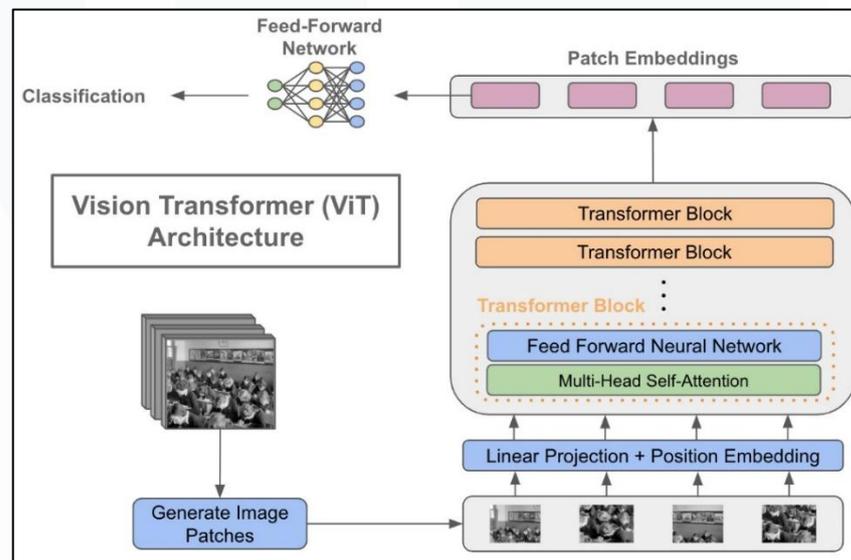
Gambar 2. 3 Model Arsitektur Transformer [37]

Gambar 2.3 menunjukkan arsitektur dasar *Transformer* yang terdiri dari *encoder* dan *decoder* [37]. *Input* diubah menjadi vektor melalui *embedding* dan diberi *positional encoding*. *Encoder* memproses data dengan *multi-head attention* dan *feed forward*, sedangkan *decoder* menambahkan *masked attention* untuk mencegah melihat *token* berikutnya. *Output* akhir melewati lapisan *linier* dan *softmax* untuk menghasilkan prediksi. Arsitektur ini memungkinkan pemrosesan paralel dan efisien dalam tugas seperti teks dan citra.

2.2.4 Vision Transformer (ViT)

Istilah Vision Transformer pertama kali diperkenalkan dalam publikasi ilmiah berjudul *An Image is Worth 16x16 Words: Transformer for Image Recognition at Scale* yang ditulis oleh Dosovitskiy dan rekan-rekannya pada tahun 2020 [38]. *Vision Transformer* (ViT) merupakan pengembangan terbaru yang

menerapkan prinsip *Transformer* untuk data visual, dengan memanfaatkan teknik *patch embedding*, *multi-head attention*, dan *multi-layer perceptron* guna menghasilkan analisis citra yang lebih efektif dan mendalam [16]. Cara Kerja *ViT* dalam memproses gambar yaitu gambar dipecah menjadi beberapa *patch* kecil, lalu diubah menjadi urutan *vektor* menggunakan *proyeksi linier* [39]. *Patch* ini diberi *embedding posisi* dan diproses oleh *encoder Transformer*. Hasil akhir dari proses ini digunakan untuk *klasifikasi gambar*. Gambar model arsitektur *ViT* ditampilkan pada Gambar 2.4.



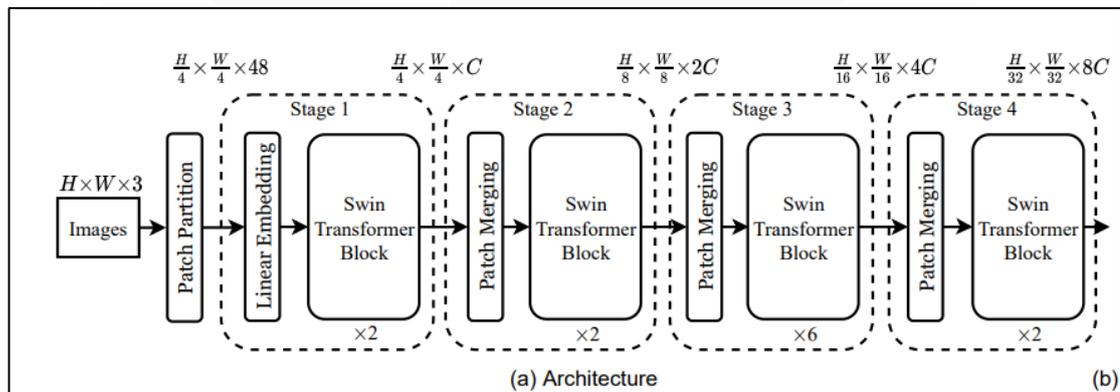
Gambar 2. 4 Arsitektur ViT [40]

Gambar 2.4 ini menampilkan arsitektur *Vision Transformer (ViT)*, yang memanfaatkan struktur *encoder-only transformer* yang dipakai untuk pengolahan citra [40]. Alur dimulai dari pemecahan citra menjadi *patches*, kemudian setiap *patch* diproyeksikan secara *linear* dan ditambahkan *positional embedding* untuk mempertahankan informasi spasial. Rangkaian *patch embedding* tersebut kemudian diproses melalui beberapa lapisan *transformer encoder*, di mana setiap *transformer block* terdiri dari *multi-head self-attention* untuk menangkap hubungan global antar *patch* dan *feed-forward network* untuk menambahkan kemampuan representasi non-linier. Akhirnya, *token* khusus seperti *cls* atau fungsi *pooling* mengumpulkan

informasi global citra, yang kemudian diteruskan ke *MLP head* untuk menghasilkan klasifikasi akhir.

2.2.5 Swin Transformer

Swin Transformer (*Shifted Window Transformer*) adalah arsitektur model *deep learning* berbasis *Transformer* yang dirancang khusus untuk pemrosesan citra (*computer vision*) [35]. Dimana model ini merupakan pengembangan lanjutan dari ViT, yang dirancang dengan struktur hierarkis dan mekanisme *shifted window* untuk meningkatkan efisiensi serta akurasi dalam pengolahan citra [17]. Dengan membatasi *self-attention* pada jendela lokal yang bergeser di setiap *layer*, *Swin Transformer* mampu menangkap informasi global dengan kompleksitas komputasi yang lebih rendah, dan terbukti unggul dalam berbagai tugas visi komputer seperti klasifikasi gambar, deteksi objek, dan segmentasi semantik. Gambar arsitektur *Swin transformer* ditampilkan pada Gambar 2.5.



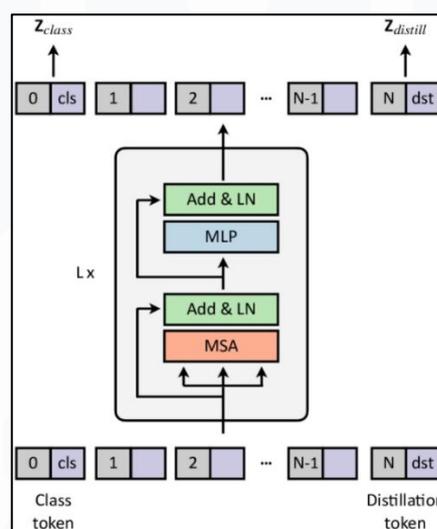
Gambar 2. 5 Artitektur Swin Transformer [41]

Gambar 2.5 menunjukkan arsitektur *backbone* dari *Swin Transformer*, yang terdiri dari beberapa tahap (*stage*) berurutan yang masing-masing terdiri atas proses *patch merging* dan *Swin Transformer Block* [41]. Proses dimulai dari pemecahan citra menjadi potongan-potongan kecil (*patch partition*) yang kemudian melalui lapisan *embedding linear* pada Stage 1. Setelah itu, setiap tahap berikutnya (*Stage 2* hingga *Stage 4*) melakukan *patch merging*, yaitu penggabungan empat *patch* berdekatan (2×2) menjadi satu *patch* yang vektornya dikonsolidasikan dari ukuran $4C$ menjadi $2C$ melalui lapisan *linear*. Proses ini secara otomatis memperkecil

dimensi spasial (lebar dan tinggi) dari fitur secara bertahap. Setiap hasil dari *patch merging* kemudian diproses oleh blok *Swin Transformer* untuk menangkap informasi lokal dan *spasial* secara efisien. Dengan demikian, arsitektur ini menghasilkan fitur *multi-scale* dari citra yang dapat digunakan untuk berbagai tugas visi komputer seperti klasifikasi, deteksi objek, dan segmentasi.

2.2.6 Data-efficient Image Transformers (DeiT)

Data-efficient Image Transformers (DeiT) juga merupakan pengembangan model lain dari ViT, yang menonjol dalam efisiensi penggunaan data dan komputasi [18]. DeiT dirancang agar lebih ringan dan cepat tanpa mengorbankan akurasi, serta tersedia dalam beberapa varian seperti *DeiT Base* dan *DeiT Tiny*, sehingga dapat disesuaikan dengan kebutuhan komputasi yang berbeda. Model ini tidak menggunakan lapisan konvolusi dan mampu memberikan performa yang kompetitif, DeiT juga dikembangkan dengan tujuan agar tetap dapat mencapai performa tinggi tanpa ketergantungan pada data besar atau pretraining yang mahal karena tidak membutuhkan dataset berskala besar dan sumber daya komputasi yang tidak terlalu tinggi [42]. Dimana keunggulan utama DeiT adalah adanya *token distilasi*, yaitu bagian khusus dalam model yang belajar dari model lain yang lebih besar dan sudah dilatih sebelumnya. Gambar model arsitektur DeiT ditampilkan pada Gambar 2.6.

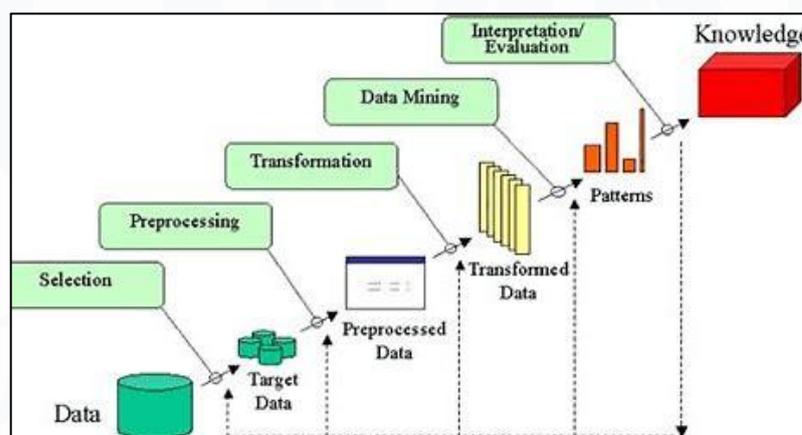


Gambar 2. 6 Arsitektur DeiT [43]

Gambar 2.6 menampilkan arsitektur model *Data-efficient Image Transformer* (DeiT) yang memperkenalkan dua token khusus, yaitu *class token* (cls) dan *distillation token* (dst). Keduanya dimasukkan bersama *patch embedding* dari citra ke dalam *blok transformer* yang terdiri dari modul *Multi-Head Self Attention* (MSA) dan *Multi-Layer Perceptron* (MLP) yang masing-masing dilengkapi dengan operasi *Add & Layer Normalization*. Output dari *class token* digunakan untuk klasifikasi seperti pada *Vision Transformer* (ViT) biasa, sedangkan *distillation token* diarahkan untuk meniru *output* dari model teacher (biasanya CNN) dalam skema pembelajaran distilasi. Pendekatan ini memungkinkan DeiT mencapai performa tinggi meskipun hanya dilatih menggunakan dataset terbatas, seperti *ImageNet-1K*, tanpa memerlukan *pretraining* pada dataset besar seperti JFT-300M.

2.2.7 KDD

KDD (*Knowledge Discovery in Databases*) adalah metode yang memanfaatkan teknik data mining untuk menemukan pola tersembunyi dalam data besar yang digunakan untuk mendeteksi kanker kulit secara lebih akurat dan efisien. KDD terdiri dari beberapa tahapan, seperti pemilihan data, pra-pengolahan, transformasi, data mining, dan evaluasi hasil. Secara umum, KDD juga dikenal sebagai proses penemuan pengetahuan dalam basis data [11]. Gambar metode KDD ditampilkan pada Gambar 2.7.



Gambar 2. 7 Tahapan KDD [44]

Gambar 2.7 merupakan proses menemukan dan menginterpretasi pola dari data dilakukan dalam beberapa langkah. Pertama, dilakukan pemahaman tentang domain aplikasi dan tujuan pengguna. Kemudian, dipilih dataset yang relevan untuk analisis dan dilakukan pembersihan data, seperti menghapus *noise* dan menangani data yang hilang. Selanjutnya, dilakukan reduksi data untuk memilih fitur yang penting, diikuti dengan pemilihan tugas *data mining*, seperti klasifikasi atau *clustering*, dan pemilihan algoritma yang sesuai. Proses data mining dilakukan untuk mencari pola dalam data, dan hasilnya diinterpretasi untuk mendapatkan pengetahuan yang berguna. Proses ini bertujuan untuk menghasilkan wawasan yang dapat digunakan untuk pengambilan keputusan lebih lanjut.

2.2.8 Confusion Matrix

Confusion matrix merupakan tabel evaluasi yang digunakan untuk menggambarkan jumlah prediksi yang benar dan salah dari hasil pengujian model klasifikasi [45]. Melalui tabel ini, performa sistem klasifikasi dapat dianalisis secara lebih rinci, termasuk dalam mengidentifikasi letak kesalahan prediksi yang terjadi selama proses klasifikasi. Gambar *confusion matrix* ditampilkan pada Gambar 2.8.

		PREDICTED	
		Positive	Negative
ACTUAL	Positive	TRUE POSITIVE	FALSE NEGATIVE
	Negative	FALSE POSITIVE	TRUE NEGATIVE

Gambar 2. 8 Confusion Matrix [46]

Gambar 2.8 menampilkan gambar tabel evaluasi yang terbagi menjadi empat bagian utama, yaitu: [47]

1. *True Positive* (TP): kondisi saat data yang seharusnya positif berhasil diprediksi dengan benar sebagai positif.

2. *True Negative* (TN): kondisi saat data yang seharusnya negatif juga berhasil diprediksi sebagai negatif.
3. *False Positive* (FP): kondisi ketika data yang sebenarnya negatif justru diprediksi sebagai positif.
4. *False Negative* (FN): kondisi ketika data yang sebenarnya positif diprediksi sebagai negatif.

Dalam penerapannya, *confusion matrix* digunakan sebagai dasar untuk menghitung metrik evaluasi penting seperti akurasi, spesifisitas, sensitivitas, dan AUC, yang semuanya digunakan untuk menilai secara menyeluruh kinerja dan efektivitas suatu model klasifikasi dalam membedakan antara kelas positif dan negatif. Seperti dijabarkan dengan rumus perhitungan seperti [48]:

1. Akurasi

Akurasi merupakan ukuran yang merepresentasikan proporsi keseluruhan data yang berhasil diklasifikasikan dengan benar oleh model, baik untuk kelas positif maupun negatif [49]. Rumus akurasi dihitung pada Rumus 2.1.

$$\frac{(TP + TN)}{(TP + FP + FN + TN)}$$

Rumus 2. 1 Akurasi [48]

2. Sensitivitas (*Recall*)

Sensitivitas, atau yang juga dikenal sebagai *recall*, adalah metrik evaluasi yang mengukur sejauh mana model mampu mengenali dan memprediksi data yang termasuk dalam kategori positif secara tepat [49]. Rumus sensitivitas dihitung pada Rumus 2.2.

$$\frac{TP}{(TP + FN)}$$

Rumus 2. 2 Sensitivitas [48]

3. Spesifisitas

Spesifisitas mengindikasikan kemampuan model dalam mengidentifikasi data dari kelas negatif secara akurat, ditunjukkan dalam bentuk persentase dari total data negatif yang terklasifikasi dengan benar [50]. Rumus spesifisitas dihitung pada Rumus 2.3.

$$\frac{TN}{(TN + FP)}$$

Rumus 2. 3 Spesifisitas [48]

4. AUC

AUC mengacu pada luas area di bawah kurva ROC (*Receiver Operating Characteristic*), yang mencerminkan kemampuan model dalam membedakan antara kelas positif dan negatif, dengan nilai berkisar antara 0 hingga 1 [48]. Rumus AUC dihitung pada Rumus 2.4.

$$\frac{\text{Sensitifitas} + \text{Spesifisitas}}{2}$$

Rumus 2. 4 AUC [48]

Rumus-rumus evaluasi tersebut digunakan untuk mengukur seberapa baik performa suatu model klasifikasi [48]. Akurasi menunjukkan proporsi prediksi yang benar secara keseluruhan, sementara sensitivitas (*recall*) menilai kemampuan model dalam mengenali data positif. Di sisi lain, spesifisitas mengukur ketepatan model dalam mengidentifikasi data negatif, dan AUC mencerminkan seberapa baik model dalam membedakan antara dua kelas secara menyeluruh.

UNIVERSITAS
MULTIMEDIA
NUSANTARA