

Adaptive Medical Image Quality Assessment **untuk Solusi *Telemedicine* Indonesia**

Irwan Prasetya Gunawan

Pendahuluan

Indonesia menghadapi tantangan disparitas pelayanan kesehatan yang kompleks dan multidimensi sebagai konsekuensi uniknya kondisi geografis, sosial ekonomi, dan struktural yang dimilikinya. Dengan jumlah pulau melebihi 17 ribu yang tersebar di wilayah geografis yang sangat luas, penyediaan pelayanan kesehatan yang adil bagi seluruh masyarakat merupakan tantangan alamiah yang harus dihadapi (Global Burden of Disease Study 2019 Indonesia Collaborators, dalam Septiono, 2023). Tantangan ini menjadi semakin kompleks dengan beragamnya etnis sebanyak lebih dari 1300 suku yang memiliki bahasa daerah masing-masing agar bisa mendapatkan akses kesehatan yang setara tersebut.

Kondisi disparitas ini terlihat lebih mengkhawatirkan jika kita membandingkan data antar provinsi. Sebuah studi secara analitik sistematis yang merupakan hasil kolaborasi antara jaringan peneliti dan pembuat kebijakan dari lembaga pemerintah dan institusi akademik di Indonesia, termasuk Kementerian Perencanaan Pembangunan, Kementerian Kesehatan, dan Badan Pusat Statistik yang dilaporkan oleh Septiono (2013) menunjukkan adanya perbedaan harapan hidup yang sangat lebar, dengan kesenjangan sebesar 10,2 tahun yaitu antara 75,4 tahun di Bali dengan 65,2 tahun di Papua. Perbedaan yang lebih ekstrim malahan ditunjukkan oleh data harapan hidup perempuan, yaitu dengan disparitas sebesar 13,7 tahun antara Kalimantan Utara (77,7 tahun) dan Maluku Utara (64,0 tahun).

Dimensi Kesenjangan

Disparitas kesehatan di Indonesia bermanifestasi dalam berbagai dimensi yang saling berkaitan. Kesenjangan ini tidak hanya terlihat dari perbedaan geografis antara daerah urban dan rural, tetapi juga mencakup ketimpangan berdasarkan status sosial-ekonomi dan jenis layanan kesehatan yang dibutuhkan masyarakat.

Pada dimensi geografis, disparitas akses layanan kesehatan ditunjukkan antara daerah urban dan rural di Indonesia. Sebuah studi ekstensif dengan melibatkan sampel representatif nasional serta lintas-bagian (Laksono, Soedirham & Wulandari, 2022) menunjukkan bahwa seseorang yang tinggal di daerah urban memiliki peluang 1,493 kali lebih tinggi untuk menggunakan layanan *outpatient* rumah sakit dibandingkan dengan mereka yang tinggal di daerah rural, dan 1,075 kali lebih tinggi untuk layanan *inpatient*. Sementara untuk kombinasi layanan *outpatient* dan *inpatient*, kesenjangannya mencapai 1,208 kali lebih tinggi. Hasil studi ini mungkin mencerminkan kondisi faktual di Indonesia, terutama di daerah berpenduduk jarang seperti Papua, yang memiliki sedikit rumah sakit sehingga masyarakat harus menempuh puluhan kilometer untuk mengakses fasilitas kesehatan ini. Kondisi ini bahkan lebih buruk lagi untuk daerah-daerah yang sulit seperti perbukitan dan pegunungan.

Mirip dengan kesenjangan geografis, pola disparitas ini juga ditunjukkan oleh utilisasi rumah sakit, dengan daerah Papua secara konsisten menjadi daerah dengan akses kesehatan terendah di Indonesia. Data *Indonesian Basic Health Survey 2018* mengungkapkan bahwa responden di Sumatra, Jawa-Bali, dan Nusa Tenggara secara berturut-turut memiliki peluang lebih tinggi sebesar 1,079, 1,075, dan 1,106 kali dibandingkan dengan responden di Papua (Laksono, , Rohmah, Rukmini & Wulandari, 2023).

Disparitas dalam akses layanan kesehatan juga terlihat pada bidang sosial-ekonomi. Hal ini ditunjukkan oleh hasil studi Indonesia *Family Life Survey* (IFLS), yang merupakan studi lintas bidang yang

melibatkan 42.083 partisipan dewasa dari 13 provinsi yang mewakili 83% populasi Indonesia menggunakan *Relative Index of Inequality* (RII) sebagai ukuran besaran ketimpangan (Kunst, Kringos & Mulyanto, 2019). Hasil analisis menunjukkan ketimpangan yang bervariasi berdasarkan jenis layanan: ketimpangan pendidikan yang kecil ditemukan untuk *primary care utilization* (RII 1,13), namun ketimpangan yang lebih besar teridentifikasi untuk *outpatient secondary care* (RII 10,35) dan *inpatient care* (RII 2,78) (Kringos, Kunst & Mulyanto, 2019).

Yang tidak kalah mengkhawatirkan adalah adanya ketimpangan besar pada layanan *preventive care*, khususnya untuk pengecekan gula darah (RII 30,31) dan ECG (*electrocardiography*) (RII 30,90). Ketimpangan ini sebagian besar disebabkan oleh batasan geografis, yaitu lokasi fasilitas *secondary care* dan spesialis yang berada di daerah urban sehingga menimbulkan biaya tak-langsung yang cukup besar bagi masyarakat kurang mampu berupa biaya perjalanan dan *opportunity cost* untuk mengakses fasilitas, meskipun mereka mendapatkan tanggungan biaya medis melalui program asuransi kesehatan nasional (Kringos, Kunst & Mulyanto, 2019).

Tantangan Struktural dan Sistemik

Akar permasalahan disparitas kesehatan di Indonesia terletak pada tantangan struktural dan sistemik yang mendalam. Mulai dari distribusi tenaga kesehatan yang tidak merata, keterbatasan infrastruktur teknologi informasi, hingga implementasi program jaminan kesehatan universal yang belum optimal, semuanya berkontribusi pada melebarnya kesenjangan yang ada.

Distribusi tenaga kesehatan spesialis di Indonesia menunjukkan ketimpangan yang ekstrem dan mencerminkan konsentrasi sumber daya yang tidak merata. Data menunjukkan bahwa 80% spesialis medis terpusat di koridor Jawa-Bali, sementara daerah lain, khususnya Indonesia bagian timur, mengalami kekurangan tenaga spesialis yang akut. Laporan *International Labour Organization* (ILO) tahun 2015

mengungkapkan bahwa 56% populasi rural global tidak memiliki akses terhadap layanan kesehatan penting, hampir tiga kali lipat dibandingkan populasi urban (22%). Sementara, hanya 23% tenaga kesehatan bertugas di sistem kesehatan rural meskipun hampir setengah populasi global tinggal di daerah tersebut.

Analisis disparitas sistem informasi kesehatan berdasarkan *Health Facilities Research* 2019 yang mencakup 9.831 *Community Health Centers* menunjukkan performa terbaik yang ditunjukkan oleh daerah Jawa-Bali dan diikuti oleh Sumatera; sebaliknya, Papua dan Papua Barat memiliki kurang dari 60% untuk semua jenis program penyimpanan data (Nugraheni, Putri & Sanjaya, 2023). Ketersediaan fasilitas kesehatan terburuk berada di provinsi dengan hasil kesehatan yang buruk, menciptakan tantangan yang berat bagi sumber daya pemerintah yang terbatas untuk mempersempit disparitas besar antar provinsi.

Meskipun implementasi *Universal Health Coverage* melalui Badan Penyelenggara Jaminan Sosial Kesehatan (BPJS) sejak 2014 telah mencakup lebih dari 75% populasi Indonesia, disparitas dalam akses dan kualitas layanan kesehatan masih tetap bertahan. Terlepas dari adanya indikasi perkembangan pada status kesehatan keseluruhan, disparitas antara provinsi dengan performa tertinggi dan terendah justru semakin lebar sejak 1990, dengan distribusi sumber daya yang tidak merata dan tingkat utilisasi fasilitas kesehatan yang rendah. Sementara fasilitas kesehatan publik telah berubah dari *pro-rich* menjadi *pro-poor*, fasilitas kesehatan privat masih memberikan keuntungan bagi masyarakat berpenghasilan tinggi yang sebagian besar terfokus di daerah urban (Johar *et al.*, 2018).

Digital divide dalam sistem informasi kesehatan Indonesia mencerminkan disparitas geografis yang lebih luas dan memperparah tantangan dalam penyediaan layanan kesehatan yang merata. Meskipun sudah ada format perekaman dan pelaporan untuk pusat kesehatan dalam sistem informasi standar, berbagai aplikasi kesehatan masih perlu memenuhi kebutuhan setiap program.

Kemampuan entri data di pusat kesehatan masyarakat bervariasi tergantung pada jumlah karyawan, kemampuan sumber daya manusia, perangkat elektronik, dan dukungan organisasi seperti jaringan Internet yang tersedia. Namun pada akhirnya, kondisi yang menyebabkan disparitas antar wilayah dan provinsi pada akhirnya mempengaruhi sistem informasi kesehatan.

Meskipun dalam kurun waktu dekade terakhir (2010-2021) populasi orang lanjut usia di Indonesia mengalami peningkatan sebesar 10,82% pada tahun 2021, minat para lansia untuk mencari pengobatan di fasilitas kesehatan justru menurun. Analisis komprehensif untuk layanan *telemedicine geriatric* di Kota Padang, Sumatera Barat, menggunakan pendekatan *Human-Organization-Technology Fit* dan *Sociotechnical System* mengidentifikasi sepuluh dimensi kunci untuk layanan *telemedicine* geriatrik yang mencakup aspek teknologi, infrastruktur, alur kerja, dan keuangan (Syahlani *et al.*, 2024).

Kompleksitas dan persistensi masalah disparitas kesehatan di Indonesia menuntut pendekatan solusi yang inovatif dan komprehensif. Era digital saat ini menawarkan peluang besar untuk memanfaatkan berbagai macam teknologi seperti *computer vision* dan *artificial intelligence* (AI) sebagai instrumen strategis dalam menjembatani kesenjangan layanan kesehatan antar wilayah.

Kondisi disparitas yang kompleks dan multidimensi ini menunjukkan kebutuhan mendesak untuk solusi inovatif yang dapat mengatasi tantangan berganda secara simultan. Proses pengembangan kemampuan untuk memantau kesenjangan kesehatan di Indonesia telah dilakukan selama 20 bulan. Proses ini menghasilkan berbagai produk, termasuk laporan nasional tentang kesenjangan kesehatan dan beberapa publikasi. Namun, masih diperlukan sistem pemantauan yang lebih canggih untuk mengolah data yang lebih terperinci dari berbagai kelompok masyarakat (Hosseinpoor, Nambiar & Schlottheuber, 2018). Indonesia menghadapi masalah ganda penyakit menular dan tidak menular yang bervariasi antar provinsi.

Kesenjangan kesehatan antara provinsi terbaik dan terburuk terus melebar sejak 1990.

Era kontemporer ditandai dengan banyaknya informasi visual dalam dunia digital. Hal ini membuka peluang untuk menggunakan teknologi penglihatan komputer dan kecerdasan buatan sebagai cara strategis mengatasi kesenjangan layanan kesehatan di Indonesia. Berbagai masalah penting saling berkaitan dan menunjukkan bahwa solusi teknologi terpadu sangat dibutuhkan. Masalah-masalah seperti kesenjangan geografis dengan perbedaan harapan hidup 10,2 tahun antar daerah, 80% dokter spesialis yang terpusat di Jawa-Bali, kesenjangan sosial ekonomi yang sangat tinggi dalam layanan kesehatan pencegahan, kesenjangan digital dengan kemampuan teknologi di bawah 60% di Papua dan Papua Barat, serta jumlah lansia yang terus bertambah, menunjukkan bahwa *telemedicine* yang didukung teknologi-teknologi terkini dalam bidang *computer vision/AI* menjadi kebutuhan mendesak yang tidak bisa ditunda lagi.

***Telemedicine* sebagai Solusi Strategis**

Telemedicine pada masa kini berkembang sebagai salah satu solusi strategis dan inovatif untuk mengurangi disparitas geografis dalam akses layanan kesehatan. Perjalanan perkembangannya menunjukkan lintasan sejarah yang panjang, seiring evolusi teknologi komunikasi yang terus bertransformasi. Sejak masa awal peradaban, manusia telah berusaha saling berbagi informasi terkait kesehatan, misalnya melalui hieroglif atau gulungan kuno yang mencatat peristiwa wabah dan epidemi. Beberapa komunitas juga memanfaatkan sinyal asap sebagai sarana peringatan dini bagi pemukiman terdekat terhadap potensi penyebaran penyakit (Gajjarawala & Pelkowski, 2021). Memasuki abad ke-19, penemuan telepon dan mesin tik mengubah pola komunikasi antara pasien dan tenaga medis, sementara telegraf dimanfaatkan untuk menyampaikan informasi mengenai korban dan mengkoordinasikan bantuan medis, sebagaimana tercatat pada masa Perang Saudara di Amerika Serikat.

Perkembangan *telemedicine* modern mulai terlihat pada dekade 1950-an, didorong oleh kemunculan teknologi televisi. Pada 1959, Nebraska Psychiatric Institute mulai memanfaatkan teknologi *video conferencing* untuk layanan *telepsychiatry* (Gajarawala & Pelkowski, 2021). National Aeronautics and Space Administration (NASA) juga berperan signifikan dalam memajukan konsep *telemedicine* modern. Salah satu penerapan awal di Amerika Serikat dilakukan oleh NASA pada awal 1960-an untuk memantau kondisi kesehatan astronot selama penerbangan melalui dukungan tim medis dalam misi *Project Mercury* (Kichloo *et al.*, 2020). Dalam praktiknya, NASA menunjuk seorang *medical monitor* yang bertanggung jawab mendalami riwayat kesehatan astronot sekaligus meneliti dampak lingkungan luar angkasa terhadap tubuh manusia. Oleh karena itu, perkembangan *telemedicine* modern tidak dapat dilepaskan dari kemajuan teknologi komunikasi dan riset antariksa yang mendorong transformasi layanan kesehatan hingga saat ini.

World Health Organization (WHO) mendefinisikan *telemedicine* sebagai pemberian layanan kesehatan jarak jauh oleh tenaga profesional melalui pemanfaatan teknologi informasi dan komunikasi (Alabdulkarim *et al.*, 2023). Definisi yang lebih luas mendeskripsikan *telemedicine* sebagai pemberian layanan medis maupun layanan kesehatan secara umum dari jarak jauh, yang meliputi pemantauan, diagnosis, konsultasi, diskusi kasus, pengajaran, hingga prosedur bedah jarak jauh (Liu *et al.*, 2022). Selain itu, *telemedicine* juga mencakup pemberian layanan klinis secara *real-time* maupun *asynchronous* antara pasien dan dokter, atau antar sesama dokter, ketika kedua pihak berada di lokasi yang berbeda dengan memanfaatkan berbagai bentuk teknologi informasi dan komunikasi (Reed *et al.*, 2022).

Dalam skala global, perkembangan *telemedicine* telah mengalami akselerasi yang signifikan dalam beberapa dekade terakhir. Mahar *et al.* (2018) mencatat bahwa pada 2016 sekitar 61% institusi kesehatan di Amerika Serikat dan 40% hingga 50% rumah sakit telah menerapkan layanan *telemedicine*. Antara 2012 hingga 2013, pasar

telemedicine tercatat mengalami pertumbuhan sebesar 60%, dengan estimasi sekitar 7 juta pasien di Amerika Serikat memanfaatkan layanan ini dalam satu tahun. Analisis bibliometrik yang dilakukan Li *et al.* (2024) terhadap literatur *telemedicine* dari 2001 hingga 2022 juga menunjukkan peningkatan signifikan publikasi akademik di bidang ini dalam satu dekade terakhir, dengan mayoritas penelitian dilakukan oleh institusi di negara-negara berpendapatan tinggi.

Kemajuan teknologi menjadi salah satu pendorong utama adopsi *telemedicine* dengan berbagai modalitas yang semakin canggih. Saat ini, *telemedicine* mencakup beragam aplikasi spesialis, di antaranya *teleradiology* untuk interpretasi citra medis jarak jauh, *teleelectrocardiography* untuk pemantauan kondisi jantung, *teleultrasonography* untuk pemeriksaan *ultrasound* jarak jauh, serta *teleconsultation* klinis untuk konsultasi interaktif antara pasien dan tenaga medis (Alabdulkarim *et al.*, 2023). Penerapan *electronic intensive care units (e-ICUs)* juga telah meningkatkan kapasitas pemantauan pasien secara simultan, sehingga pada kondisi dengan lonjakan pasien rawat inap, sistem *e-ICU* dapat membantu dokter dalam mengelola beban kerja secara lebih efisien (Kichloo *et al.*, 2020).

Perkembangan *Telemedicine* di Indonesia

Perkembangan *telemedicine* di Indonesia menunjukkan kemajuan yang signifikan dan mencerminkan komitmen pemerintah untuk mengatasi tantangan disparitas geografis. Pemerintah Indonesia telah mengenali potensi *telemedicine* sejak awal, ditandai dengan peluncuran platform nasional bernama *Temenin* oleh Kementerian Kesehatan pada 2017. *Temenin* berfungsi sebagai platform *telemedicine* nasional dengan berbagai fitur komprehensif, seperti *teleradiology* untuk interpretasi citra medis jarak jauh, *tele-EKG* untuk pemantauan kondisi jantung, *tele-USG* untuk pemeriksaan *ultrasonography* jarak jauh, serta *teleconsultation* untuk konsultasi interaktif. Selain itu, platform ini didukung kolaborasi strategis dengan sekitar 200 rumah sakit dan pusat kesehatan masyarakat (*Puskesmas*) di seluruh Indonesia (Ivanocalzha *et al.*, 2023).

Kerangka regulasi *telemedicine* di Indonesia mulai dibangun dengan diterbitkannya Peraturan Menteri Kesehatan Republik Indonesia Nomor 20 Tahun 2019 tentang Penyelenggaraan Pelayanan *Telemedicine* antar Fasilitas Pelayanan Kesehatan (Sukoco *et al.*, 2020). Kebijakan ini dihadirkan sebagai upaya untuk menjamin hak masyarakat dalam memperoleh akses layanan kesehatan jarak jauh, terutama bagi pasien kasus non-darurat yang menghadapi keterbatasan akses ke rumah sakit rujukan, khususnya di wilayah terpencil.

Selain inisiatif pemerintah, sektor swasta juga memainkan peran penting dalam membangun ekosistem *telemedicine* yang dinamis di Indonesia. Salah satu contohnya adalah *HaloDoc*, aplikasi *telemedicine* yang mengalami pertumbuhan pesat, khususnya pada masa pandemi. *HaloDoc* yang diluncurkan pada 2016 di Jakarta oleh Jonathan Sudharta, berkembang menjadi salah satu platform kesehatan terkemuka di Indonesia. Hingga 2018, total pendanaan yang diperoleh mencapai sekitar USD 13 juta atau setara Rp170 miliar, dengan dukungan investor seperti Gojek, Blibli, Clermont, dan NSI Ventures (Ivanocalzha *et al.*, 2023). Saat ini, layanan *telemedicine* di Indonesia tersedia melalui situs web maupun aplikasi mobile, dengan sedikitnya 17 platform yang telah bermitra dengan Kementerian Kesehatan, membentuk ekosistem layanan kesehatan digital yang terintegrasi.

Pandemi COVID-19 menjadi *unprecedented catalyst* bagi percepatan adopsi *telemedicine* secara global, termasuk di Indonesia. Sebelum pandemi, pemanfaatan *telemedicine* di Indonesia terbilang terbatas dan belum sepenuhnya menjadi praktik umum. Namun, pada masa pandemi, pelonggaran regulasi dan peningkatan paritas pembayaran mendorong lonjakan penggunaan layanan *telemedicine* yang bersifat *exponential* (Reed *et al.*, 2022). Di Indonesia, pergeseran dari konsultasi tatap muka ke layanan daring memicu peningkatan penggunaan aplikasi *telemedicine* hingga 600%, termasuk aplikasi yang dikembangkan oleh *start-up* kesehatan digital maupun rumah sakit. Hingga 6 April 2020, tercatat sekitar 15 juta orang mengakses

aplikasi *telemedicine* untuk memperoleh informasi terkait *coronavirus*, menggambarkan tingkat adopsi yang luar biasa dalam waktu singkat (Handayani *et al.*, 2022).

Sebagai respons terhadap situasi tersebut, pemerintah Indonesia menerbitkan berbagai regulasi untuk mendukung penerapan *telemedicine* secara lebih luas. Salah satunya adalah Keputusan Menteri Kesehatan Nomor HK.01.07/Menkes/4829/2021 tentang Pedoman Pelayanan Kesehatan melalui *Telemedicine* selama Pandemi Coronavirus Disease 2019 (Rahayu *et al.*, 2024). Kebijakan ini melengkapi regulasi sebelumnya yang dikeluarkan pada 2020, yang memberikan kewenangan bagi dokter untuk melaksanakan praktik *telemedicine* di rumah sakit tempat mereka bertugas selama masa pandemi.

Selain kebijakan dan infrastruktur, perilaku pengguna juga menjadi faktor penting dalam kesuksesan adopsi *telemedicine*. Penelitian Handayani *et al.* (2022) terhadap 534 responden di Indonesia berusia 17 tahun ke atas yang mengenal atau pernah menggunakan aplikasi *teleconsultation* rumah sakit menunjukkan bahwa dimensi perilaku dan teknologi berpengaruh signifikan terhadap intensi perilaku untuk memanfaatkan layanan *telemedicine*. Faktor-faktor seperti *contamination avoidance*, keselamatan, keandalan, profesionalisme, *perceived ease of use*, *perceived usefulness*, serta kualitas informasi terbukti memiliki dampak positif terhadap niat menggunakan aplikasi *telemedicine* rumah sakit.

Manfaat, Tantangan, dan Sustainability Telemedicine

Telemedicine memberikan berbagai manfaat komprehensif yang terbukti secara empiris dapat meningkatkan akses pasien terhadap layanan medis sekaligus menurunkan beban biaya kesehatan. Ketika menggunakan *telemedicine* sebagai alternatif konsultasi tatap muka, pasien umumnya mengalami pengurangan waktu tunggu, eliminasi atau penurunan kebutuhan perjalanan, penghematan biaya transportasi, serta efisiensi dalam pemanfaatan fasilitas kesehatan

(Alabdulkarim *et al.*, 2023). Selain itu, *telemedicine* memungkinkan penyedia layanan kesehatan untuk menjangkau populasi yang tinggal di komunitas terisolasi, termasuk individu dengan keterbatasan fisik atau perkembangan, lansia, pasien di lembaga pemasyarakatan, hingga kelompok masyarakat yang tinggal di daerah terpencil secara geografis maupun budaya.

Namun demikian, situasi pasca-pandemi menimbulkan tantangan keberlangsungan *telemedicine* yang tidak dapat diabaikan. Kristianti *et al.* (2024) mencatat bahwa penggunaan *telemedicine* di Indonesia meningkat hingga 600% selama pandemi COVID-19 pada 2020. Akan tetapi, pasca-pandemi, tingkat pemanfaatannya menurun drastis, dengan hanya sekitar 5% pengguna yang tetap menggunakan layanan ini. Penurunan ini sebagian disebabkan oleh berkurangnya perhatian masyarakat terhadap layanan daring, sehingga banyak orang kembali memilih kunjungan langsung ke fasilitas kesehatan.

Meskipun *telemedicine* diakui sebagai salah satu solusi yang menjanjikan untuk mengurangi kesenjangan layanan kesehatan, implementasinya masih menghadapi tantangan signifikan terkait kualitas yang dapat memengaruhi akurasi diagnosis serta efektivitas pengobatan. Beberapa penelitian menunjukkan bahwa proporsi citra medis yang dikirim melalui platform *telemedicine* sering kali tidak memenuhi standar kualitas minimum untuk mendukung diagnosis yang tepat (Vodrahalli *et al.*, 2020; Jalaboi *et al.*, 2022). Degradasi kualitas gambar berisiko menurunkan akurasi diagnosis hingga 35%, sementara sebagian besar konsultasi daring—hingga 60%—sering kali memerlukan pengiriman ulang citra akibat kualitas transmisi yang tidak memadai (Vodrahalli *et al.*, 2020). Lathan *et al.* (2022) juga mencatat bahwa sensitivitas diagnosis luka pasca operasi melalui gambar jarak jauh hanya sekitar 64%, lebih rendah dibandingkan pemeriksaan tatap muka yang dapat mencapai 88%. Selain itu, variasi kecepatan bandwidth di berbagai wilayah, yang berkisar antara 25 hingga 2000 kbps, turut mempersulit transmisi citra medis beresolusi tinggi yang sangat diperlukan dalam konteks klinis (Lee *et al.*, 2003). Temuan-temuan ini menunjukkan bahwa tantangan teknis masih

menjadi hambatan penting yang perlu diatasi agar *telemedicine* dapat berfungsi secara optimal dan berkelanjutan.

Anandari *et al.* (2024) mengidentifikasi sejumlah faktor pendukung *telemedicine* di Indonesia, seperti peningkatan akses, kenyamanan layanan, peningkatan derajat kesehatan masyarakat, serta optimalisasi perawatan melalui teknologi *mobile*. Meski demikian, berbagai hambatan masih dihadapi, antara lain distribusi layanan kesehatan dan tenaga medis yang belum merata, literasi digital yang rendah, kualitas jaringan yang tidak stabil, serta tantangan terkait perlindungan privasi dan keamanan data pasien. Keterbatasan dalam melakukan pemeriksaan secara fisik juga membatasi ruang lingkup diagnosis dan pengobatan jarak jauh.

Selain isu kualitas, aspek kepercayaan dan persepsi pengguna menjadi faktor penting. Rahayu *et al.* (2024) mencatat bahwa mayoritas pengguna *telemedicine* (61%) mengkhawatirkan risiko *misdiagnosis*, sedangkan 52,9% lainnya menyoroti kekhawatiran terkait keamanan dan kerahasiaan data pasien. Survei yang dilakukan di Indonesia pada September 2023 juga menunjukkan bahwa 23% responden memandang tarif layanan yang relatif tinggi sebagai salah satu kelemahan utama, menandakan bahwa *affordability* masih menjadi perhatian krusial.

Guna menjawab tantangan kompleks tersebut, diperlukan penelitian lanjutan mengenai persepsi masyarakat terhadap *telemedicine*, pengembangan teknologi yang semakin canggih, serta inovasi untuk menyediakan sumber daya listrik dan koneksi internet berbiaya rendah guna mendukung akses layanan kesehatan digital. Di samping itu, rekomendasi kebijakan konseptual perlu dikembangkan melalui analisis situasi yang matang dan melibatkan kerja sama lintas pemangku kepentingan, termasuk Kementerian Kesehatan Indonesia, Kementerian Komunikasi dan Informatika, Badan Pengawas Obat dan Makanan, serta asosiasi kesehatan terkait, guna membangun ekosistem *telemedicine* yang berkelanjutan dan efektif.

Komunikasi Visual dalam *Telemedicine*

Dalam praktik *telemedicine*, komunikasi visual melalui citra dan video medis merupakan komponen krusial yang berpengaruh langsung terhadap keberhasilan diagnosis maupun penatalaksanaan pasien. *Cisco Visual Networking Index* (VNI) memproyeksikan bahwa lalu lintas IP global akan mencapai 4,8 zettabyte per tahun, dengan proporsi lalu lintas video IP diperkirakan meningkat hingga 82% dari total lalu lintas internet (Webster, 2017). Proyeksi ini menunjukkan betapa besarnya intensitas pertukaran data visual dalam aktivitas komunikasi digital, termasuk pada aplikasi di bidang kesehatan.

Kualitas gambar dalam layanan *telemedicine* sangat menentukan akurasi diagnosis jarak jauh. Boissin *et al.* (2016) melalui penilaian kualitatif terhadap pakar medis pada praktik *image-based teleconsultation* berbasis *smartphone* dan *tablet* menemukan bahwa mutu citra menjadi faktor penentu utama dalam keberhasilan diagnosis. Sejalan dengan temuan tersebut, Poleshchenko *et al.* (2023) menekankan pentingnya standarisasi kualitas citra pada praktik *diagnostic radiology* guna menjamin ketepatan diagnosis.

Di sisi teknologi, sistem *computer vision* dapat mendukung tenaga kesehatan dengan menganalisis citra medis melalui algoritma yang mampu mendeteksi pola secara lebih presisi dibandingkan observasi konvensional. *Computer vision* sendiri merupakan bidang interdisipliner yang memadukan prinsip matematika, ilmu komputer, dan rekayasa untuk mengembangkan sistem yang dapat memahami serta menginterpretasikan informasi visual (Szeliski, 2010).

Pada implementasinya, teknologi *computer vision* bekerja dengan meniru mekanisme kompleks sistem visual biologis, melalui tahapan akuisisi citra, *preprocessing*, ekstraksi fitur, interpretasi tingkat tinggi, hingga pengambilan keputusan. Ketersediaan *framework open-source* seperti TensorFlow, PyTorch, dan OpenCV turut mendemokratisasi pengembangan aplikasi *computer vision*,

sehingga semakin mempermudah penerapannya pada layanan *telemedicine*.

Meskipun demikian, tantangan mendasar dalam komunikasi visual *telemedicine* adalah memastikan bahwa citra medis yang ditransmisikan memiliki kualitas yang memadai untuk mendukung diagnosis yang akurat. Faktor-faktor seperti pencahayaan yang tidak ideal, keterbatasan bandwidth, perbedaan kemampuan perangkat, serta gangguan (*noise*) selama transmisi dapat menurunkan mutu citra secara signifikan. Oleh karena itu, dibutuhkan penerapan teknologi *image enhancement* atau peningkatan citra yang andal guna menjamin kualitas visual optimal dalam praktik *telemedicine*.

Image Enhancement

Konsep Dasar dan Metode Tradisional *Image Enhancement*

Image enhancement atau peningkatan gambar merupakan proses fundamental dalam pengolahan citra yang bertujuan untuk meningkatkan kualitas visual gambar sesuai dengan kebutuhan spesifik, dengan evolusi yang luar biasa dari pendekatan matematika klasik di era 60-an hingga sistem kecerdasan buatan (*artificial intelligence*) yang canggih saat ini. Dalam konteks *telemedicine*, *image enhancement* menjadi sangat penting karena kualitas gambar secara langsung mempengaruhi akurasi diagnosis dan efektivitas layanan medis jarak jauh. Pemrosesan citra didefinisikan sebagai proses pengolahan dan analisis digital terhadap representasi visual untuk ekstraksi informasi yang bernilai bagi sistem persepsi manusia (Gonzalez & Woods, 2018), yang memfasilitasi manipulasi, perbaikan, analisis, dan interpretasi gambar untuk pencapaian tujuan spesifik.

Algoritma *image enhancement* tradisional telah menjadi standar dalam pengolahan citra medis selama beberapa dekade, dengan berbagai teknik yang telah terbukti secara empiris mampu meningkatkan kualitas visual sebagaimana dilihat oleh mata manusia (*human visual system*, HVS). Sebagai contoh, *histogram equalization* (Gonzalez & Woods, 2018) merupakan salah satu teknik dasar yang

paling banyak digunakan untuk meningkatkan kualitas gambar yang memiliki masalah kontras rendah, seperti citra medis yang diambil dalam kondisi pencahayaan yang kurang optimal. *Histogram equalization* bekerja dengan memperbaiki kontras gambar melalui pendistribusian ulang intensitas piksel gambar untuk mencapai distribusi histogram yang lebih merata. Secara matematis, *histogram equalization* dapat direpresentasikan sebagai transformasi fungsi:

$$s = T(r) = (L - 1) \int_0^r p_r(w)dw$$

dengan s adalah intensitas output, r adalah intensitas input, L adalah jumlah semua tingkatan intensitas piksel yang mungkin, dan $p_r(w)$ merupakan *probability density function* dari gambar input (Patel et al., 2013). Patel et al. (2013) melakukan studi komparatif komprehensif yang menunjukkan bahwa teknik *histogram equalization* dapat secara signifikan meningkatkan kecerahan dan kontras gambar medis, meskipun dengan keterbatasan dalam retensi detail halus dan potensi munculnya artefak pada daerah gambar tertentu. Keterbatasan teknik *histogram equalization* yang bersifat global pada gambar ini dijawab dengan adanya teknik serupa yang bersifat lokal dan adaptif, seperti *Adaptive Histogram Equalization* (AHE) dan *Contrast Limited Adaptive Histogram Equalization* (CLAHE) yang menggunakan *clipping limit* untuk mencegah amplifikasi berlebihan pada *noise* dalam wilayah seragam (Zuiderveld, 1994).

Metode peningkatan gambar lainnya meliputi penggunaan berbagai macam *filter*. Di bidang *computer vision* dan pengolahan citra, *filter* merujuk pada kernel operasi konvolusi dua dimensi pada gambar. Operasi konvolusi antara gambar dengan kernel filter memiliki sifat operasi matematis yang mirip dengan mencari korelasi antara bagian kecil gambar (*patch*) dengan kernel filter dan menghasilkan keluaran berupa nilai piksel gambar yang merupakan kombinasi linear nilai-nilai piksel gambar *input* menggunakan nilai kernel filter sebagai koefisiennya.

Teknik *filtering* konvensional mencakup berbagai pendekatan yang canggih untuk pengurangan *noise* dan *enhancement*. *Gaussian filter*, dengan kernel yang didefinisikan secara matematis sebagai $G(x,y) = (1/2\pi\sigma^2)e^{-(x^2+y^2)/2\sigma^2}$, efektif untuk mengurangi *noise* frekuensi tinggi sambil tetap mempertahankan informasi *edge* atau tepian objek yang penting untuk diagnosis medis. *Median filter*, yang menggantikan setiap piksel dengan nilai *median* dari piksel-piksel tetangga, sangat efektif untuk menghilangkan *impulse noise* atau *salt-and-pepper noise* yang sering terjadi dalam sistem pencitraan medis. Kedua jenis filter ini meskipun cukup efektif dalam mengurangi *noise* pada gambar, sering kali berdampak negatif pada intensitas tepian objek, mengakibatkan penurunan ketajaman gambar. Ini terjadi karena pada dasarnya kedua filter ini bekerja dengan cara ‘memperhalus’ bagian gambar yang terkontaminasi *noise*, namun sayangnya ini juga bisa jadi mengubah nilai intensitas piksel bagian gambar yang penting seperti tepian objek (*edge*).

Berbeda dengan teknik filter konvensional seperti Gaussian dan median filter, *bilateral filter* merepresentasikan kemajuan signifikan dalam operasi pemfilteran gambar sambil tetap mempertahankan tingkat ketajaman gambar (*edge-preserving smoothing*).

Konsep *bilateral filter* pertama kali diperkenalkan oleh Tomasi & Manduchi (1998), dan prinsipnya adalah penggabungan dua jenis Gaussian filter yang memiliki tugas berbeda; yang pertama bertanggung jawab untuk mengurangi *noise* secara spasial, sementara filter kedua melakukan tugasnya dengan memperhitungkan sifat keragaman nilai intensitas piksel yang berdekatan, untuk menghindari reduksi berlebihan terhadap intensitas piksel yang menjadi bagian gambar yang penting (seperti tepian objek). Operasi peningkatan gambar dengan menggunakan *bilateral filter* dinyatakan dalam sebuah persamaan yang memberikan nilai keluaran piksel hasil di lokasi x sebagai berikut:

$$I_{BF}(x) = \frac{1}{W_p} \sum_{x_i \in \Omega} I(x_i) \cdot f_s(|x_i - x|) \cdot f_r(|I(x_i) - I(x)|)$$

dengan faktor normalisasi yang bertujuan agar hasil penjumlahan di atas terkalibrasi:

$$W_p = \sum_{x_i \in \Omega} f_s(|x_i - x|) \cdot f_r(|I(x_i) - I(x)|)$$

dan:

- $I(x)$ adalah intensitas piksel pada posisi x .
- $I_{BF}(x)$ adalah intensitas piksel hasil *bilateral filtering* di posisi x .
- Ω adalah jendela filter di sekitar piksel pusat, misalnya dengan ukuran $(2k + 1) \times (2k + 1)$ piksel
- f_s adalah *spatial kernel* berupa fungsi Gaussian yang menggunakan parameter lokasi dan jarak piksel x_i dengan piksel pusat x .
- f_r adalah *range kernel* berupa fungsi Gaussian yang menimbang kesamaan nilai intensitas piksel.

Penggunaan *bilateral filter* memungkinkan proses *smoothing* yang selektif, yaitu mengurangi *noise* dalam wilayah seragam sambil tetap mempertahankan detail *edge* atau tepian objek penting yang kritis untuk interpretasi medis.

Selain *bilateral filter*, penggunaan kombinasi *filtering* ganda juga dapat memberikan peningkatan kualitas gambar yang cukup signifikan, khususnya pada gambar dengan tingkat *noise* tinggi yang

kerap muncul dalam praktik *telemedicine* dalam lingkungan yang memiliki keterbatasan bandwidth dan gangguan transmisi. Pendekatan *cascaded filtering*, yakni penerapan berurutan beberapa *filter*, memungkinkan penanganan berbagai bentuk degradasi secara simultan, asalkan urutan proses dan parameter *filtering* diatur secara optimal.

Selain itu, algoritma-algoritma lainnya untuk peningkatan citra, seperti *unsharp masking* dan *Laplacian filtering* (Gonzalez & Woods, 2018; Jalaly et al., 2020; Kostilek & St'astny, 2012; Marcel & Millan, 2007; McDonnell, 1981), juga telah terbukti efektif dalam meningkatkan ketajaman *edge* serta memperjelas detail pada gambar medis. Metode *unsharp masking* bekerja dengan mengurangi versi citra yang dihaluskan dari citra aslinya, berdasarkan karakteristik gambar dan kebutuhan aplikasi. Selain itu, Chen, Wang, & Qiu (2019) memperkenalkan *Hausdorff derivative Laplacian operator* yang menunjukkan kinerja superior dalam penajaman gambar dibandingkan metode konvensional, dengan fondasi matematika yang kuat dan efisiensi komputasi yang lebih baik.

Deep Learning dan Convolutional Neural Networks dalam Peningkatan Gambar


Konsep *Convolutional Neural Networks* (CNN) pertama kali berhasil diterapkan secara praktis untuk pengenalan pola dokumen oleh LeCun et al. (1998) dan sejak itu berkembang menjadi salah satu fondasi utama dalam berbagai terobosan *deep learning* modern (Goodfellow, Bengio, & Courville, 2016; LeCun, Bengio, & Hinton, 2015). Terobosan ini telah merevolusi metode peningkatan kualitas gambar dengan memanfaatkan kemampuan model untuk mengekstraksi dan mempelajari pola non-linear yang kompleks, yang sering kali tidak dapat diungkap oleh teknik *filtering* tradisional. Dalam praktiknya, metode peningkatan citra generasi terbaru menempatkan CNN sebagai komponen inti berkat arsitektur hierarkinya yang dirancang secara optimal untuk menangkap fitur spasial serta konteks lokal secara mendetail. Keunggulan ini menjadikan CNN sangat

relevan untuk peningkatan kualitas gambar medis, yang biasanya memiliki detail visual yang presisi yang kerap kali menjadi penentu akurasi diagnosis dan pengambilan keputusan klinis.

Secara umum, arsitektur CNN terdiri dari beberapa lapisan dengan fungsi spesifik: *convolutional layers* berperan untuk mengekstraksi fitur visual, *pooling layers* berfungsi mereduksi dimensi data sambil mempertahankan informasi penting, dan *fully connected layers* digunakan untuk penalaran tingkat tinggi atau klasifikasi. Arsitektur umum ini bisa dilihat ilustrasinya pada Gambar 1 di bawah ini. Operasi konvolusi yang menjadi inti CNN dapat direpresentasikan secara matematis sebagai berikut:

$$C(i,j) = (I * K)(i,j) = \sum_m \sum_n I(i+m, j+n)K(m,n)$$


Di sini C adalah hasil konvolusi, I adalah gambar masukan, dan K merupakan kernel atau *filter* yang bobotnya dapat dipelajari. Tidak seperti *filter* tetap pada teknik tradisional, CNN mampu menyesuaikan bobot *filter* secara dinamis melalui proses pelatihan *backpropagation*, sehingga model dapat dioptimalkan sesuai dengan karakteristik tugas dan dataset tertentu.




Gambar 1. Arsitektur umum CNN yang dikenal sebagai LeNet (LeCun *et al.*, 1988)

Dari arsitektur dasar CNN seperti ini lahirlah berbagai macam varian arsitektur lain yang lebih kompleks. Misalnya, U-Net (Ronneberger et al., 2015), pada Gambar 2, yang memiliki struktur *encoder-decoder* simetris dan *skip connections* untuk memfasilitasi preservasi detail resolusi tinggi, telah menunjukkan kinerja luar biasa dalam peningkatan kualitas citra medis. Begitu pula halnya dengan arsitektur ResNet (*Residual Networks*), pada Gambar 3, yang diajukan oleh He et al. (2016) yang memperkenalkan konsep revolusioner dari pembelajaran residual: $H(x) = F(x) + x$, dengan $F(x)$ adalah fungsi residual yang dipelajari oleh jaringan. Pendekatan ini mengatasi masalah *vanishing gradient* dan memungkinkan pelatihan jaringan yang sangat dalam untuk kinerja yang lebih baik dalam tugas *image enhancement* yang kompleks. Sementara itu Li et al. (2022) memperkenalkan arsitektur CNN berdasarkan *encoder-decoder* dengan *skip connections* menggunakan mekanisme *attention* dan pemrosesan multi-skala untuk mengatasi permasalahan kondisi pencahayaan yang kurang, sehingga metode peningkatan kualitas gambarnya mampu menjaga keseimbangan antara tingkat kecerahan dan preservasi detail. Desain arsitektur ini juga dilengkapi dengan modul adaptasi luminansi yang menyesuaikan parameter pencahayaan secara otomatis sehingga informasi penting pada gambar untuk tujuan diagnostik tetap terjaga.

Dengan kemampuan menjaga detail resolusi tinggi pada saat meningkatkan kualitas gambar seperti ini, maka metode berbasis CNN atau *deep learning* seperti yang sudah dipaparkan di atas sangat mungkin untuk diterapkan pada praktik *telemedicine* di daerah-daerah terpencil di Indonesia. Misalnya, kita bisa menggunakan metode-metode peningkatan kualitas gambar berbasis CNN/*deep learning* tersebut pada saat pengambilan gambar dalam kondisi pencahayaan yang kurang mendukung karena keterbatasan infrastruktur. Atau, kita bisa juga menggunakan metode-metode tersebut untuk menjaga kualitas gambar pada saat dikirimkan melalui jaringan atau Internet dalam kondisi keterbatasan akses bandwidth seperti halnya yang sangat mungkin terjadi di daerah-daerah terpencil.



Gambar 2. Arsitektur U-Net dengan resolusi terendah pada 32×32 piksel, dengan komponen kotak biru menggambarkan *multi-channel feature map*. Jumlah *channel* diberikan di atas box, sementara ukuran gambar/map diberikan di sisi kiri masing-masing box. Ilustrasi dan penjelasan diambil dari Ronneberger *et al.* (2015)




Gambar 3. Blok dasar dari residual *network* pada ResNet (He *et al.*, 2016).

Generative Adversarial Networks

Loncatan berikutnya dalam perkembangan teknik perbaikan kualitas gambar berbasis CNN adalah penggunaan arsitektur *Generative Adversarial Networks* (GAN) yang dicetuskan oleh

Goodfellow, I. et al. (2014). Arsitektur ini dianggap cukup revolusioner paradigmatik dalam bidang *computer vision* dan *image enhancement* karena kemampuannya untuk menghasilkan atau meningkatkan kualitas gambar dengan tingkat realisme yang tinggi dan kualitas persepsi yang superior. Arsitektur GAN terdiri dari dua *neural networks* yang berkompetisi dalam *zero-sum game* (Goodfellow, I. et al, 2014; Creswell et al., 2018): 1) generator *G* yang berusaha menghasilkan gambar yang realistis untuk "menipu" *discriminator*, dan 2) *discriminator* *D* yang berusaha membedakan antara gambar asli dan gambar yang dihasilkan. Dengan arsitektur ganda seperti ini, GAN menawarkan pendekatan yang lebih canggih dan adaptif dalam peningkatan kualitas gambar medis untuk aplikasi *telemedicine*. Ilustrasi arsitektur dasar konsep GAN yang diadaptasi dari Goodfellow, I. et al. (2014) diberikan pada Gambar 4.



Gambar 4. Arsitektur konsep dasar *Generative Adversarial Networks* (GAN) yang dicetuskan oleh Goodfellow, I. et al. (2014). Gambar diambil dari Kora Venu, S., & Ravula, S. (2020).

Dalam konteks *image enhancement*, GAN dapat dilatih untuk mempelajari pemetaan kompleks dari gambar berkualitas rendah ke gambar berkualitas tinggi melalui proses pelatihan *adversarial*. Sebagai contoh, *Super-Resolution GAN* (SRGAN) adalah salah satu contoh arsitektur GAN yang paling sukses dalam meningkatkan resolusi gambar dengan menghasilkan detail frekuensi tinggi yang realistis dan meyakinkan secara perseptif (Ledig et al., 2017). Salah satu problem mendasar dalam citra *super-resolution* adalah terjadinya degradasi detail gambar setelah gambar ditingkatkan resolusinya karena proses interpolasi piksel gambar pada resolusi tinggi yang kurang sempurna. Metode berbasis SRGAN bisa mengatasi problem ini karena SRGAN menggunakan kombinasi dari *adversarial loss* dan *perceptual loss* yang berdasarkan fitur yang diekstrak dari jaringan *neural network* VGG (Simonyan & Zisserman, 2015) yang telah dilatih sebelumnya, sehingga menghasilkan gambar yang tidak hanya memiliki resolusi lebih tinggi tetapi juga kualitas persepsi yang lebih baik karena detail pada gambar yang terlihat lebih realistik.

Enhanced Deep Super-Resolution (EDSR) dan *Residual Dense Network* (RDN) telah menunjukkan kemampuan luar biasa dalam *single image super-resolution* dengan desain arsitektur yang inovatif. EDSR (Lim et al., 2017) menghilangkan lapisan *batch normalization* yang tidak perlu dan menggunakan *residual scaling* untuk stabilitas pelatihan yang lebih baik, sementara RDN (Zhang et al., 2018) memperkenalkan konsep dari *residual dense blocks* yang memfasilitasi penggunaan ulang fitur dan aliran gradien yang lebih baik. Zhang et al. (2018) memperkenalkan *Residual Dense Networks* yang dapat mengekstrak fitur hierarki dengan sangat efektif, menghasilkan kualitas rekonstruksi yang superior untuk aplikasi medis dengan detail anatomi halus yang tetap terjaga.

Selanjutnya, Pix2Pix dan CycleGAN telah membuka kemungkinan revolusioner untuk *image-to-image translation* yang dapat digunakan untuk adaptasi domain dalam citra medis. Pix2Pix (Isola et al., 2017) menggunakan data pelatihan berpasangan untuk mempelajari pemetaan dari gambar input ke gambar output dengan

kerangka *conditional GAN*. Sementara itu, *CycleGAN* memperluas konsep ini untuk data yang tidak berpasangan menggunakan kerangka *cycle consistency loss*; dengan cara seperti ini, metode *CycleGAN* memungkinkan translasi antara domain yang berbeda tanpa memerlukan contoh berpasangan (Zhu *et al.*, 2017).

Kedua pendekatan di atas, terutama kerangka *CycleGAN*, memungkinkan konversi antara modalitas pencitraan yang berbeda atau *enhancement* dari satu domain ke domain lainnya tanpa memerlukan data pelatihan berpasangan, yang sangat berharga dalam aplikasi medis pada kondisi yang tidak memungkinkan diperolehnya gambar medis berkualitas tinggi/rendah yang berpasangan. Contohnya adalah ketika kita melakukan konversi citra *CT scan* dengan dosis rendah ke citra berkualitas tinggi, peningkatan gambar *ultrasound* untuk mendapatkan visualisasi yang lebih baik, ataupun standardisasi gambar dari pembuat dan protokol akuisisi yang berbeda.

Teknik *Enhancement Modern*

Penggunaan *Convolutional Neural Networks* (CNN) telah menjadi pondasi utama dalam berbagai aplikasi pengolahan citra digital, mulai dari klasifikasi hingga segmentasi. Untuk tugas-tugas generatif seperti *image synthesis*, *image-to-image translation*, atau *super-resolution*, pendekatan *deep learning* berbasis pembelajaran adversarial melalui kerangka *Generative Adversarial Networks* (GAN) memanfaatkan CNN sebagai komponen inti, baik pada generator maupun *discriminator*.

Kombinasi CNN dengan skema *adversarial* secara luas diakui sebagai salah satu pendekatan *state-of-the-art* untuk menghasilkan citra sintetis dengan tingkat realisme tinggi yang sulit dicapai metode konvensional. Namun demikian, untuk tugas diskriminatif seperti klasifikasi citra, deteksi objek, atau ekstraksi fitur, berbagai arsitektur CNN murni — termasuk ResNet, DenseNet, VGG, dan EfficientNet —

masih mendominasi performa terkini tanpa harus bergantung pada mekanisme *adversarial*.

Dengan demikian, GAN dapat dipandang sebagai kerangka generatif yang memaksimalkan potensi CNN melalui kompetisi antara generator dan *discriminator*. Kerangka ini telah menjadi standar penting di bidang sintesis citra realistis, meski bukan satu-satunya representasi dari keseluruhan kemajuan arsitektur CNN modern.

Perkembangan CNN dan GAN juga telah membuka peluang inovasi dalam teknik peningkatan kualitas citra. Salah satunya adalah penerapan *attention mechanism* dalam jaringan saraf, sebagaimana ditunjukkan oleh Wang *et al.* (2022) melalui metode *multi-level image brightness enhancement* dengan mekanisme perhatian adaptif. Arsitektur yang mereka usulkan mencakup jaringan dekomposisi untuk memisahkan konten dan iluminasi, modul *reference-guided enhancement* yang menyesuaikan proses peningkatan sesuai karakteristik target, serta jaringan fusi yang mengintegrasikan informasi dari berbagai tingkat pencahayaan. Pendekatan ini memungkinkan model untuk secara selektif menyoroti area penting, sehingga detail diagnostik tetap terjaga meski kondisi pencahayaan tidak ideal.

Selain itu, strategi optimasi berbasis metaheuristik seperti *Cuckoo Search* (Maurya *et al.*, 2022) telah diterapkan untuk meningkatkan proses *image fusion*, terutama pada penggabungan data medis multi-modal. Dengan mengintegrasikan algoritma *Cuckoo Search* ke dalam kerangka CNN atau GAN, bobot fusi dapat disesuaikan secara adaptif guna memaksimalkan preservasi informasi spasial dan spektral dari berbagai sumber citra. Pendekatan ini mengadopsi perilaku biologis burung cuckoo dalam berkembang biak menggunakan strategi *egg laying* dan *Levy flight random walks* untuk menemukan parameter optimal di ruang pencarian multi-dimensi yang kompleks.

Mekanisme perhatian dalam jaringan peningkatan citra modern memungkinkan model fokus pada area dan fitur relevan, sehingga kualitas *enhancement* dan efisiensi komputasi meningkat. Modul *self-attention* dapat mengidentifikasi bagian gambar yang perlu diperjelas dan area yang harus dilestarikan, menghasilkan proses peningkatan yang lebih adaptif. *Channel attention* dan *spatial attention* bekerja saling melengkapi, memberikan panduan komprehensif bagi operasi *image enhancement*. Kombinasi teknik optimasi metaheuristik, pembelajaran adversarial, dan modul perhatian adaptif menjadikan pendekatan ini relevan untuk mendukung diagnosis berbasis citra dengan kualitas visual yang optimal.

Terakhir, perkembangan arsitektur berbasis *transformer* untuk peningkatan kualitas citra menunjukkan hasil yang menjanjikan (Dosovitskiy *et al.*, 2021; Khan *et al.*, 2021). *Vision Transformers* (ViTs) yang diadaptasi untuk tugas *image enhancement* memproses citra sebagai urutan potongan (*patches*), memungkinkan model menangkap dependensi jarak jauh dan konteks global dengan lebih baik — aspek yang krusial untuk aplikasi medis yang memerlukan detail spasial yang presisi.

Image Quality Assessment (IQA)

Pada masa era digital saat ini, pertukaran citra medis lintas jarak menjadi suatu hal yang umum dilakukan sehingga kemampuan untuk mengevaluasi kualitas visual gambar secara objektif menjadi semakin krusial. Dalam konteks *telemedicine*, penilaian kualitas gambar (*Image Quality Assessment*, IQA) menjadi hal yang sangat penting untuk bisa memastikan sejauh mana informasi visual dapat diandalkan dalam mendukung proses diagnosis dan pengambilan keputusan klinis. Dengan cara seperti ini, maka kendala geografis karena beragamnya kondisi daerah terpencil yang mengakibatkan terjadinya ketimpangan akses layanan kesehatan bisa dimitigasi.

Secara umum, metrik IQA tradisional seperti *Peak Signal-to-Noise Ratio (PSNR)* (Hore & Ziou, 2010) dan *Structural Similarity Index (SSIM)* (Wang et al., 2004), masih banyak digunakan untuk menilai kualitas hasil pemrosesan gambar. PSNR, meski populer karena kemudahan komputasinya, seringkali menunjukkan hasil yang berkorelasi rendah terhadap persepsi visual manusia karena sifat metriknya yang hanya menilai perbedaan intensitas piksel. SSIM, di lain pihak, menawarkan pendekatan yang lebih relevan dengan persepsi manusia karena mempertimbangkan faktor-faktor seperti luminansi, kontras, dan struktur dalam perhitungan metrik kualitasnya. Seiring berkembangnya teknologi, metrik persepsi modern seperti *Learned Perceptual Image Patch Similarity (LPIPS)* (Zhang et al., 2018) mulai menunjukkan keberadaannya. LPIPS memanfaatkan fitur mendalam (*deep features*) dari model pembelajaran mendalam (*deep learning*) untuk menilai kemiripan persepsi antara gambar asli dan gambar hasil rekonstruksi atau peningkatan.

Model pengukuran kualitas berbasis AI seperti LPIPS menunjukkan kemampuan luar biasa dalam mengemulasi persepsi visual manusia untuk penilaian kualitas gambar. Model ini dapat dilatih menggunakan *dataset* komprehensif yang mengandung gambar dengan berbagai tipe distorsi dan skor kualitas subjektif yang sesuai. Dengan menggunakan pendekatan *deep learning* seperti ini, maka model IQA yang dibentuk akan bersifat lebih *robust* terhadap berbagai tipe distorsi and kondisi penglihatan. Integrasi dengan teknik *transfer learning* memungkinkan model berbasis AI ini untuk dapat digunakan pada berbagai domain yang berbeda. Hal ini sangat relevan dengan pengaplikasiannya pada domain *telemedicine* yang bisa melibatkan penggunaan gambar medis dari berbagai modalitas dan kondisi akuisisi gambar yang sangat beragam.

Berdasarkan ketersediaan referensi yang menjadi rujukan dalam proses penilaian kualitas gambar olahan, IQA dapat diklasifikasikan menjadi tiga kelompok utama: metode *Full-Reference (FR)*, *No-Reference (NR)*, dan *Reduced-Reference (RR)*, sebagaimana dijelaskan

oleh Wang & Bovik (2006). Metode FR memerlukan gambar acuan utuh dengan ukuran atau resolusi yang sama dengan gambar olahan/rekonstruksi, sementara NR tidak memerlukan gambar pembanding sama sekali. Di antara kedua ekstrem ini, metode RR dapat memanfaatkan informasi parsial dari gambar asli sebagai rujukan yang tereduksi dalam proses penilaian, dengan ukuran informasi parsial yang jauh lebih kecil daripada ukuran gambar aslinya.

Penerapan IQA tentunya tidak hanya terbatas pada pengukuran gambar medis. Di berbagai domain lain — seperti sistem keamanan visual dan perangkat *mobile* — algoritma IQA bisa dimanfaatkan untuk membantu meningkatkan kualitas citra secara otomatis. Dalam sistem keamanan, misalnya, kualitas gambar dari kamera pengawasan menentukan kemampuan identifikasi wajah atau aktivitas mencurigakan. Dalam aplikasi smartphone, algoritma IQA memfasilitasi optimasi otomatis untuk produksi fotografi berkualitas tinggi. Namun, di bidang kesehatan digital, IQA memegang peranan krusial karena kualitas citra *X-ray*, *CT scan*, atau MRI secara langsung dapat mempengaruhi akurasi diagnosis yang dilakukan oleh tenaga kesehatan.


Dalam konteks Indonesia yang memiliki kondisi disparitas geografis dan keterbatasan infrastruktur sehingga dapat mempengaruhi kualitas gambar medis pada layanan *telemedicine* akibat munculnya degradasi serta distorsi gambar yang tidak diinginkan, penerapan IQA modern berpotensi mendukung pendeteksian mutu gambar secara otomatis. Dengan demikian, citra yang tidak layak pakai dapat teridentifikasi sejak awal, sehingga akurasi diagnosis tetap terjaga meskipun dilakukan jarak jauh.

Kerangka AMIQAF-ITDS sebagai Solusi Integratif

Untuk mengatasi tantangan kompleks dalam implementasi *telemedicine* di Indonesia, diperlukan suatu kerangka kerja yang mampu mengintegrasikan algoritma peningkatan kualitas citra (*image enhancement*) tingkat lanjut dengan tetap mempertimbangkan

karakteristik infrastruktur serta kebutuhan spesifik di Indonesia. *Adaptive Medical Image Quality Assessment Framework for Indonesian Telemedicine Deployment Systems* (AMIQAF-ITDS) merupakan kerangka kerja yang dirancang secara khusus untuk menjawab tantangan khas yang dihadapi dalam penerapan telemedicine di Indonesia. Secara ringkas, kerangka kerja ini diberikan pada Gambar 5.

Kerangka kerja AMIQAF-ITDS memadukan algoritma peningkatan kualitas citra mutakhir dengan penyesuaian terhadap kondisi infrastruktur dan kebutuhan pengguna. Komponen utamanya meliputi: penilaian kualitas adaptif (*adaptive quality assessment*) yang mampu menyesuaikan parameter evaluasi berdasarkan jenis citra medis dan kondisi pengambilan gambar; algoritma peningkatan kualitas secara *real-time* yang dioptimalkan untuk berbagai kondisi *bandwidth* dan sumber daya komputasi; protokol standardisasi yang menjamin konsistensi penilaian kualitas di berbagai perangkat dan lokasi; serta mekanisme umpan balik (*feedback mechanism*) yang memungkinkan perbaikan berkelanjutan berdasarkan keluaran diagnosis.



Gambar 5. Konsep dasar kerangka AMIQAF-ITDS (*Adaptive Medical Image Quality Assessment Framework for Indonesian Telemedicine Deployment Systems*)

Framework ini mengadopsi pendekatan hibrida yang menggabungkan metode peningkatan kualitas citra tradisional dengan pendekatan mutakhir berbasis *Generative Adversarial Network* (GAN). Pada kondisi dengan keterbatasan sumber daya komputasi, sistem akan mengimplementasikan metode tradisional yang telah dioptimalkan, sedangkan untuk kebutuhan yang menuntut kualitas citra tertinggi, peningkatan berbasis GAN akan diterapkan. Pendekatan adaptif ini menjadi sangat penting mengingat variasi kemampuan infrastruktur yang masih terjadi di berbagai wilayah Indonesia.

Konvergensi berbagai isu krusial yang dapat diatasi melalui penerapan AMIQAF-ITDS tampak sangat nyata. Pertama, adanya disparitas geografis yang ekstrem—tercermin dari kesenjangan harapan hidup hingga 10,2 tahun serta konsentrasi sekitar 80% tenaga spesialis di koridor Jawa–Bali—menuntut solusi telemedicine yang mampu menjangkau daerah terpencil secara efektif.

Kedua, tingginya kegagalan kualitas gambar medis, yang terjadi pada sekitar 45% transmisi telemedicine dan berkontribusi pada penurunan akurasi diagnosis hingga 35%, menegaskan urgensi kehadiran sistem penilaian dan peningkatan kualitas citra (*image quality assessment and enhancement*) yang cerdas dan adaptif.

Ketiga, ketimpangan sosial ekonomi yang signifikan dalam akses layanan pencegahan (*preventive care*) menuntut adanya *democratisation* layanan kesehatan melalui teknologi yang dapat diakses oleh masyarakat berpenghasilan rendah (Kringos, & Kunst & Mulyanto 2019).

Keempat, kesenjangan digital (*digital divide*) yang terlihat dari variasi kecepatan bandwidth antara 25–2000 kbps menuntut pengembangan sistem adaptif yang mampu beroperasi optimal pada lingkungan dengan keterbatasan sumber daya (*resource-constrained environments*).

Kelima, pertumbuhan populasi lansia (*growing elderly population*) yang diiringi dengan penurunan tingkat pemanfaatan fasilitas kesehatan menuntut solusi telemedicine yang ramah pengguna (*user-friendly*) dan dirancang khusus untuk mendukung perawatan geriatri (*geriatric care*).

Implementasi AMIQAF-ITDS di lapangan tentu tidak terlepas dari berbagai tantangan, baik teknis maupun non-teknis. Dari sisi teknis, variasi kemampuan perangkat (*device capabilities*) dan kondisi jaringan (*network conditions*) di seluruh wilayah Indonesia menuntut adanya algoritma adaptif yang mampu beroperasi secara optimal dalam beragam situasi. Gulenko *et al.* (2022) menunjukkan bahwa

algoritma berbasis *deep learning* dapat secara efektif mengurangi *electromagnetic interference noise* pada pemrosesan citra endoskopi fotoakustik, suatu temuan yang sangat relevan mengingat gangguan elektromagnetik masih sering menjadi kendala dalam transmisi data medis di Indonesia.

Dari sisi non-teknis, proses pelatihan dan adopsi oleh tenaga kesehatan merupakan faktor penentu keberhasilan implementasi. Para profesional kesehatan perlu memahami secara mendalam kemampuan sekaligus keterbatasan teknologi peningkatan kualitas citra agar dapat menggunakannya secara tepat dalam proses diagnostik. Oleh karena itu, implementasi yang berhasil membutuhkan program pelatihan yang komprehensif dan sistem pendukung (*support system*) yang berkelanjutan.

Penutup

Disparitas kesehatan di Indonesia merupakan persoalan multidimensional yang menuntut solusi teknologi yang inovatif, terintegrasi, dan adaptif. Dengan kesenjangan harapan hidup yang dapat mencapai 10,2 tahun antar provinsi, serta konsentrasi sekitar 80% tenaga medis spesialis yang masih terpusat di koridor Jawa–Bali, implementasi telemedicine berbasis teknologi peningkatan kualitas gambar (*image enhancement*) dan penilaian mutu citra (*image quality assessment*) menjadi langkah strategis yang mendesak untuk diwujudkan.

Kerangka AMIQAF-ITDS menawarkan pendekatan terintegrasi yang memadukan metode konvensional dengan teknologi mutakhir berbasis kecerdasan buatan (*artificial intelligence*). Kerangka ini dirancang tidak hanya untuk menjawab tantangan teknis dalam penerapan *telemedicine*, tetapi juga untuk mendukung tujuan yang lebih luas, yakni mewujudkan kesetaraan layanan kesehatan dan akses kesehatan universal bagi seluruh masyarakat Indonesia.

Keberhasilan implementasi kerangka ini memerlukan kolaborasi erat berbagai pemangku kepentingan. Lembaga akademik berperan dalam riset dan inovasi, sektor industri mendukung implementasi praktis dan skala produksi, pemerintah bertanggung jawab pada penyusunan kebijakan dan regulasi, sementara masyarakat sipil terlibat melalui pemberdayaan komunitas dan advokasi. Peningkatan pendidikan dan literasi digital juga menjadi faktor kunci agar manfaat teknologi ini dapat dirasakan oleh seluruh lapisan masyarakat.

Beberapa rekomendasi yang dapat diterapkan antara lain: pengembangan *prototype* AMIQAF-ITDS yang disertai uji coba (*pilot testing*) di wilayah terpencil; penyusunan standar protokol mutu citra untuk *telemedicine* di Indonesia; pelatihan komprehensif bagi tenaga kesehatan; pembangunan infrastruktur teknologi informasi yang memadai; serta penerapan sistem pemantauan dan evaluasi yang berkesinambungan untuk perbaikan berkelanjutan.

Masa depan *telemedicine* di Indonesia sangat bergantung pada kemampuan untuk menggabungkan teknologi maju dengan pendekatan praktis yang sesuai dengan kondisi lokal. Dengan penerapan yang tepat, teknologi peningkatan kualitas gambar berbasis AI berpotensi menjadi penggerak perubahan signifikan (*game changer*) dalam menjawab tantangan disparitas layanan kesehatan, serta mendukung terwujudnya akses layanan kesehatan universal yang berkualitas bagi seluruh rakyat Indonesia.

Daftar Pustaka

- Alabdulkarim, A., Luu, S. & Prabhu, A.V., 2023. The role of telemedicine in healthcare: An overview and update. *The Egyptian Journal of Internal Medicine*, 35(1), p.39. doi:10.1186/s43162-023-00234-z.
- Ardianto, H., Dewi, R.K. & Az-Zahra, H.M., 2022. Perancangan user experience aplikasi pembelajaran digital marketing untuk UMKM dengan metode human-centered design. *Jurnal Pengembangan*.
- Bidgoly, A.J., Bidgoly, H.J. & Arezoumand, Z., 2020. A survey on methods and challenges in EEG-based authentication. *Computers & Security*. doi:10.1016/j.cose.2020.101788.
- Boissin, C., Blom, L., Wallis, L. & Laflamme, L., 2016. Image-based teleconsultation using smartphones or tablets: qualitative assessment of medical experts. *Emergency Medicine Journal*, 34(2), pp.95–99. doi:10.1136/emmermed-2015-205258.
- Creswell, A., White, T., Dumoulin, V., Arulkumaran, K., Sengupta, B. & Bharath, A.A., 2018. Generative adversarial networks: An overview. *IEEE Signal Processing Magazine*, 35(1), pp.53–65. doi:10.1109/MSP.2017.2765202.
- Dosovitskiy, A. et al., 2021. An image is worth 16×16 words: Transformers for image recognition at scale. *International Conference on Learning Representations (ICLR 2021)*. doi:10.48550/arXiv.2010.11929.
- Gonzalez, R.C. & Woods, R.E., 2018. *Digital image processing*. 4th ed. Pearson.
- Goodfellow, I., Bengio, Y. & Courville, A., 2016. *Deep learning*. MIT Press.

Goodfellow, I. et al., 2014. Generative adversarial nets. *Advances in Neural Information Processing Systems*, 27, pp.2672–2680. doi:10.48550/arXiv.1406.2661.

Gulenko, O., Yeow, J.T.W., Najafzadeh, E. & Guo, B., 2022. Deep-learning-based algorithm for the removal of electromagnetic interference noise in photoacoustic endoscopic image processing. *Sensors*, 22(10), p.3961. doi:10.3390/s22103961.

Handayani, P.W., Meigasari, D.A., Pinem, A.A., Hidayanto, A.N. & Ayuningtyas, D., 2022. Indonesian hospital telemedicine acceptance model: The influence of user behavior and technological dimensions. *Heliyon*, 8(1), p.e08835. doi:10.1016/j.heliyon.2022.e08835.

He, K., Zhang, X., Ren, S. & Sun, J., 2016. Deep residual learning for image recognition. *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, pp.770–778. doi:10.1109/CVPR.2016.90.

Hore, A. & Ziou, D., 2010. Image quality metrics: PSNR vs. SSIM. *Proceedings - International Conference on Pattern Recognition*, pp.2366–2369. doi:10.1109/ICPR.2010.579.

Isola, P., Zhu, J.Y., Zhou, T. & Efros, A.A., 2017. Image-to-image translation with conditional adversarial networks. *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, pp.1125–1134. doi:10.1109/CVPR.2017.632.

Ivanocalzha, F.A., Wisnujati, N.S., Pratama, A.C., Marpaung, S.L. & Wijoyo, H., 2023. Application based on technological advances in the health sector during a pandemic: A study of telemedicine in Indonesia from legal perspective. *Journal of Namibian Studies*, 33, pp.1765–1783. doi:10.59670/jns.v33i.1047.

- Jalaboi, R., Dragusin, L., Codres, A. & Sasu, L., 2022. ImageQX: An image quality assessment tool for teledermatology photography. *arXiv preprint* arXiv:2209.04699.
- Khan, S. et al., 2021. Transformers in vision: A survey. *ACM Computing Surveys*, 54(10), Article 200. doi:10.1145/3478184.
- Kora Venu, S. & Ravula, S., 2020. Evaluation of deep convolutional generative adversarial networks for data augmentation of chest X-ray images. *Future Internet*, 13(1), p.8. doi:10.3390/fi13010008.
- Kristianti, N.I. et al., 2024. Systematic review: The development of telemedicine in Indonesia, challenges, advantages, disadvantages, and progress for primary care services. *World Journal of Advanced Research and Reviews*, 24(1), pp.1729–1739. doi:10.30574/wjarr.2024.24.1.2978.
- Laksono, A.D., Wulandari, R.D. & Soedirham, O., 2022. Hospital utilization in Indonesia in 2018: Do urban–rural disparities exist? *BMC Health Services Research*, 22(1), p.506. doi:10.1186/s12913-022-07896-5.
- Lathan, R., Sidapra, M., Yiasemidou, M. et al., 2022. Diagnostic accuracy of telemedicine for detection of surgical site infection: A systematic review and meta-analysis. *npj Digital Medicine*, 5, p.108. doi:10.1038/s41746-022-00655-0.
- LeCun, Y., Bengio, Y. & Hinton, G., 2015. Deep learning. *Nature*, 521(7553), pp.436–444. doi:10.1038/nature14539.
- LeCun, Y., Bottou, L., Bengio, Y. & Haffner, P., 1998. Gradient-based learning applied to document recognition. *Proceedings of the IEEE*, 86(11), pp.2278–2324. doi:10.1109/5.726791.
- Ledig, C. et al., 2017. Photo-realistic single image super-resolution using a generative adversarial network. *Proceedings of the IEEE*

- Conference on Computer Vision and Pattern Recognition (CVPR)*, pp.4681–4690. doi:10.1109/CVPR.2017.19.
- Lee, S. et al., 2003. The role of low-bandwidth telemedicine in surgical prescreening. *Journal of Pediatric Surgery*, 38(9), pp.1281–1283. doi:10.1016/s0022-3468(03)00382-8.
- Li, C. et al., 2022. A low-light image enhancement method with brightness balance and detail preservation. *PLoS ONE*, 17(5), e0262478. doi:10.1371/journal.pone.0262478.
- Lim, B., Son, S., Kim, H., Nah, S. & Lee, K.M., 2017. Enhanced deep residual networks for single image super-resolution. *CVPR Workshops, NTIRE '17*, pp.470–480. doi:10.48550/arXiv.1707.02921.
- Liu, S. et al., 2022. Development and prospect of telemedicine. *Intelligent Medicine*, 2(4), pp.217–222. doi:10.1016/j.imed.2022.08.002.
- Marcel, S. & Millan, J.d.R., 2007. Person authentication using brainwaves (EEG) and maximum a posteriori model adaptation. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 29(4), pp.743–748. doi:10.1109/TPAMI.2007.1012.
- Maurya, L., Lohchab, V., Mahajan, P. & Abualigah, L., 2022. Contrast and brightness balance in image enhancement using Cuckoo Search-optimized image fusion. *Journal of King Saud University - Computer and Information Sciences*, 34(9), pp.7247–7258. doi:10.1016/j.jksuci.2021.07.008.
- McDonnell, M.J., 1981. Box-filtering techniques. *Computer Graphics and Image Processing*, 17(1), pp.65–70. doi:10.1016/S0146-664X(81)80009-3.
- Mulyanto, J., Kringos, D.S. & Kunst, A.E., 2019. Socioeconomic inequalities in healthcare utilisation in Indonesia: A

comprehensive survey-based overview. *BMJ Open*, 9(7), p.e026164. doi:10.1136/bmjopen-2018-026164.

Patel, O., Maravi, P.S. & Sharma, S., 2013. A comparative study of histogram equalization based image enhancement techniques for brightness preservation and contrast enhancement. *Signal & Image Processing: An International Journal*, 4(5), pp.11–25. doi:10.5121/sipij.2013.4502.

Poleshchenko, D.A., Silva, R.M., Santos, M.K. & others, 2023. Image quality in diagnostic radiology: A guide to methodologies for radiologists. *Radiologia Brasileira*, 56(4), pp.238–248. doi:10.1590/0100-3984.2024.0088-en.

Ronneberger, O., Fischer, P. & Brox, T., 2015. U-Net: Convolutional networks for biomedical image segmentation. In *Medical Image Computing and Computer-Assisted Intervention – MICCAI 2015*, pp.234–241. Springer. doi:10.1007/978-3-319-24574-4_28.

Septiono, W., 2023. Equity challenges in Indonesian health care. *The Lancet Global Health*, 11(5), pp.e646–e647. doi:10.1016/S2214-109X(23)00110-9.

Simonyan, K. & Zisserman, A., 2015. Very deep convolutional networks for large-scale image recognition. *International Conference on Learning Representations (ICLR)*.

Szeliski, R., 2010. *Computer vision: Algorithms and applications*. Springer. doi:10.1007/978-1-84882-935-0.

Vodrahalli, K. et al., 2020. TruelImage: A deep learning system to automatically assess image quality for teledermatology. *Pacific Symposium on Biocomputing 2021*, pp.165–176. doi:10.1142/9789811215636_0022.

- Wang, F., Chen, W. & Qiu, L., 2019. Hausdorff derivative Laplacian operator for image sharpening. *Fractals*, 27(3), 1950060. doi:10.1142/S0218348X19500609.
- Wang, Y. et al., 2022. Shedding light on images: Multi-level image brightness enhancement guided by arbitrary references. *Pattern Recognition*, 131, 108867. doi:10.1016/j.patcog.2022.108867.
- Wang, Z. & Bovik, A.C., 2006. Modern image quality assessment. *Synthesis Lectures on Image, Video, and Multimedia Processing*, 2(1), pp.1–156. doi:10.1007/978-3-031-02238-8.
- Wang, Z., Bovik, A.C., Sheikh, H.R. & Simoncelli, E.P., 2004. Image quality assessment: From error visibility to structural similarity. *IEEE Transactions on Image Processing*, 13(4), pp.600–612. doi:10.1109/TIP.2003.819861.
- Webster, D., 2017. Cisco visual networking index (VNI) global forecast update. *Cisco Systems*.
- Yang, X.S. & Deb, S., 2009. Cuckoo search via Lévy flights. *2009 World Congress on Nature & Biologically Inspired Computing (NaBIC)*, pp.210–214. doi:10.1109/NABIC.2009.5393690.
- Zhang, R. et al., 2018. The unreasonable effectiveness of deep features as a perceptual metric. *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, pp.586–595. doi:10.1109/CVPR.2018.00068.
- Zhang, Y., Tian, Y., Kong, Y., Zhong, B. & Fu, Y., 2018. Residual dense network for image super-resolution. *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, pp.2472–2481. doi:10.1109/CVPR.2018.00257.
- Zhu, J.Y., Park, T., Isola, P. & Efros, A.A., 2017. Unpaired image-to-image translation using cycle-consistent adversarial networks. *Proceedings of the IEEE International Conference on*

Computer Vision (ICCV), pp.2242–2251.
doi:10.1109/ICCV.2017.244.

Zuiderveld, K., 1994. Contrast limited adaptive histogram equalization. In: Heckbert, P.S., ed. *Graphics Gems IV*. Academic Press, pp.474–485. doi:10.1016/B978-0-12-336156-1.50061-6.