

TINJAUAN PUSTAKA

PERBANDINGAN POTENSI APLIKASI DAN PROGRAM BERBASIS CNN-ML (CONVOLUTIONAL NEURAL NETWORKS-MACHINE LEARNING) SEBAGAI DIAGNOSIS DAN SEGMENTASI ULKUS DEKUBITUS

I G Mahapraja Divasta,¹ Tracey Odella Jiraldi Akemah,¹ I Gusti Ayu Ratih Nanda Savitri¹

¹Program Studi Sarjana Kedokteran, Fakultas Kedokteran, Universitas Udayana

ABSTRAK

Pendahuluan: Ulkus dekubitus merupakan kerusakan pada kulit dan jaringan akibat adanya tekanan. Kondisi ini menjadi beban yang cukup besar terutama bagi tenaga kesehatan karena sulit untuk diprediksi dan mengklasifikasikan tingkat lesi yang terjadi. Namun, ulkus dekubitus dapat dicegah melalui beberapa cara, salah satu cara yang paling efektif dengan menggunakan alat pemeriksaan atau evaluasi yang dapat memprediksi, diagnosis, dan menilai segmentasi luka pada ulkus dekubitus.

Pembahasan: Seiring berkembangnya teknologi, kini hadir sebuah *Machine Learning* yang berfungsi meningkatkan akurasi analisis data klinis dari rekam medis elektronik dalam skala besar, yakni *Convolutional Neural Network* (CNN). CNN merupakan salah satu metode dengan menerapkan teknologi *computer vision* untuk memonitoring suatu proses penyembuhan luka secara akurat. Selain itu, CNN dapat menggolongkan jenis jaringan yang berbeda, granulasi, jaringan nekrosis, dan permukaan yang mengalami pengelupasan dalam ulkus dekubitus sehingga dapat menggolongkan tingkat keparahan luka. Berbagai aplikasi telah dikembangkan dengan menggunakan basis CNN, diantaranya algoritma AlexNet, VGG, ResNet, Inception-ResNet-v2 dalam *Pressure Ulcer Assessment System* (PUAS), U-Net, DeeplabV3, PsPnet, FPN, dan Mask R-CNN dalam Deteksi Segmentasi Luka dan Ulkus Jaringan.

Simpulan: Diantara berbagai model CNN-ML, DeeplabV3 dan Inception-ResNet-v2 memiliki nilai F1-score yang paling tinggi. Hal ini mengindikasikan bahwa dua model CNN-ML tersebut memiliki presisi dan akurasi yang baik dalam mendiagnosis dan melakukan segmentasi terhadap lesi pada ulkus dekubitus.

Kata Kunci: *Convolutional Neural Network* (CNN), *Machine Learning* (ML), Ulkus Dekubitus

ABSTRACT

Introduction: Decubitus ulcers are damage to the skin and tissue due to pressure. This condition is quite a burden, especially for health workers because it is difficult to predict and classify the level of lesions that occur. However, decubitus ulcers can be prevented in several ways, one of the most effective ways is by using examination or evaluation tools that can predict, diagnose and assess wound segmentation in decubitus ulcers.

Discussion: As technology develops, Machine Learning is now available which functions to increase the accuracy of clinical data analysis from electronic medical records on a large scale, namely Convolutional Neural Network (CNN). CNN is a method that applies computer vision technology to monitor the wound healing process accurately. In addition, CNN can classify different types of tissue, granulation, necrotic tissue, and peeling surfaces in decubitus ulcers so that it can classify the severity of the wound. Various applications have been developed using a CNN basis, including the AlexNet, VGG, ResNet, Inception-ResNet-v2 algorithms in the Pressure Ulcer Assessment System (PUAS), U-Net, DeeplabV3, PsPnet, FPN, and Mask R-CNN in Wound Segmentation Detection and Tissue Ulcers.

Conclusion: Among various CNN-ML models, DeeplabV3 and Inception-ResNet-v2 have the highest F1-score values. This indicates that the two CNN-ML models have good precision and accuracy in diagnosing and segmenting lesions in decubitus ulcers.

Keywords: *Convolutional Neural Network* (CNN), *Decubitus Ulcer*, *Machine Learning* (ML)

PENDAHULUAN

Ulkus dekubitus merupakan kerusakan pada kulit dan jaringan akibat adanya tekanan atau gesekan dalam rentang waktu yang lama. Kompresi yang sering terjadi pada tonjolan tulang dengan permukaan

eksternal dapat menimbulkan nekrosis jaringan.^[1] Kondisi ini dapat dicegah dengan baik, namun frekuensi kejadian ulkus dekubitus dalam lingkungan fasilitas kesehatan masih umum terjadi.^[2] Ulkus dekubitus merupakan suatu indikator kualitas manajemen rumah sakit dan merupakan

¹Program Studi,
Sarjana
Kedokteran,
Fakultas
Kedokteran,
Universitas
Udayana,
Bali

tantangan yang signifikan bagi perekonomian dan pusat layanan kesehatan.^[2] Berdasarkan penelitian pada tahun 2020, ditemukan angka kejadian ulkus dekubitus sebesar 12,8% secara global dalam rentang waktu tahun 2008 hingga 2018.^[3] Di Indonesia sendiri, prevalensi ulkus dekubitus mencapai 33,3%.^[4]

Tingkat insiden ulkus dekubitus bervariasi di setiap area perawatan, dimana kejadian ini paling sering ditemukan pada unit perawatan intensif dan *surgical wards*.^[5] Pasien yang terhambat mobilitasnya dan menghabiskan sebagian besar waktunya di tempat tidur atau kursi memiliki risiko tertinggi mengalami ulkus dekubitus. Pasien geriatri (≥ 60 tahun) lebih rentan terhadap ulkus dekubitus karena penurunan fungsi, integritas kulit, serta peningkatan komorbiditas yang membatasi aktivitas dan gerakan mereka. Tingginya kejadian ulkus dekubitus menunjukkan pentingnya upaya preventif yang lebih efektif. Sekitar 95% kasus ulkus dekubitus seharusnya dapat dihindari.^[2] Ulkus dekubitus dapat dicegah melalui tahapan yang efektif dan sistematis seperti pemeriksaan kulit secara berkala, mengevaluasi risiko, menyesuaikan permukaan tempat tidur dan kursi, mengganti posisi (*repositioning*) secara berkala, dan melakukan pergerakan secara rutin baik pasif atau aktif.^[6]

Menurut Coleman *et al.* pada tahun 2013 dan NPUAPA (*National Pressure Ulcer Advisory Panel and Alliance*) pada tahun 2014, menyatakan bahwa melakukan penilaian atau pengkajian risiko menjadi komponen sentral dari pencegahan ulkus dekubitus.^[6] Melalui pernyataan ini maka dalam mengoptimalkan pencegahan terhadap ulkus dekubitus diperlukan suatu alat yang secara efektif dapat memprediksi pasien yang memiliki risiko tinggi serta dapat menerapkan intervensi yang tepat. Adapun berbagai alat yang dapat digunakan untuk memprediksi kejadian ulkus dekubitus sejak tahun 1960, diantaranya Norton Scale, the Waterlow Scale, dan Braden Scale. Norton Scale merupakan alat prediksi risiko terstruktur yang pertama kali dalam memprediksi ulkus dekubitus. Namun, alat ini memiliki kelemahan yakni minimnya evaluasi pada bagian yang berpotensi untuk mengalami gesekan sehingga menyebabkan adanya kemunculan berulang ulkus dekubitus. Kemudian alat kedua yang dapat digunakan sebagai prediksi risiko ulkus dekubitus adalah Waterlow Scale, yakni sebuah alat yang dapat memeriksa kemungkinan adanya risiko ulkus pada pasien mengalami gangguan ingatan tetapi tidak akurat dalam mengidentifikasi individual yang tidak tergolong ke dalam

kelompok risiko tinggi. Spesifisitas dari Waterlow Scale adalah 32,9%.^[6]

Adapun alat yang paling umum digunakan untuk mengkaji risiko ulkus dekubitus adalah Skala Braden. Skala ini meliputi 6 kategori yaitu fungsi sensori, kelembaban, mobilitas, aktivitas, nutrisi, dan gesekan yang diakumulasikan menjadi skor untuk menilai risiko seseorang mengalami ulkus dekubitus. Akurasi dan sensitivitas skala Braden tidak menentu karena hasil yang sangat bervariasi pada berbagai penelitian. Satu studi penelitian menemukan bahwa skala Braden lebih akurat pada pasien muda (<60 tahun) dibandingkan pasien lansia. Timbulnya komorbiditas dan penurunan fungsi fisiologis pada lansia tidak dipertimbangkan pada skala Braden.^[6]

Adanya kelemahan pada alat prediksi risiko ulkus dekubitus yang sudah ada saat ini menimbulkan suatu peluang untuk penemuan metode diagnosis terbaru yang dapat dikombinasikan dengan perkembangan teknologi. Seiring berkembangnya zaman, *machine learning* (ML) dan *artificial intelligence* (AI) sudah mulai diterapkan di bidang medis sebagai alat untuk meningkatkan akurasi diagnostik dan prognosis.^[2] ML mampu meningkatkan akurasi analisis data klinis dari rekam medis elektronik dalam skala besar. Banyak algoritma ML yang telah digunakan untuk membantu manajemen ulkus dekubitus dengan menggunakan *predictive models* dan analisis gambar.^[2,7] Salah satu kelas ML yang digunakan untuk memprediksi ulkus dekubitus adalah *Convolutional Neural Network* (CNN). CNN merupakan sebuah model ML yang umum digunakan untuk mengenali dan mengklasifikasikan suatu gambar. CNN memiliki dua bagian utama, yakni lapisan konvolusi dan lapisan yang berfungsi untuk mengklasifikasikan. Salah satu aspek penting dari CNN adalah CNN dapat mempelajari fitur hierarki ketika sedang melakukan konvolusi pada suatu gambar.^[8] Oleh karena itu, dalam *literature review* ini penulis akan membandingkan berbagai modalitas *machine learning* (ML) dengan algoritma CNN (*Convolutional Neural Network*) untuk menilai efektivitas yang dimiliki sebagai alat diagnostik dan segmentasi pada Ulkus Dekubitus.

METODE

Penelitian ini dilakukan dengan menggunakan metode studi literatur melalui data sekunder. Tujuan sistematik dari mengulas artikel-artikel adalah untuk menganalisis lebih dalam terkait potensi dari berbagai aplikasi dan program diagnostik dan segmentasi dari ulkus dekubitus yang berbasis CNN-ML (*Convolutional Neural*

Network-Machine Learning) untuk menemukan modalitas aplikasi atau program yang paling efektif sebagai alat prediktor ulkus dekubitus. Jurnal yang ditelusuri menggunakan database, seperti Google Scholar, Pubmed NCBI, MDPI, dan ScienceDirect. Kata kunci yang digunakan berupa ulkus dekubitus, ML (*Machine Learning*), CNN (*Convolutional Neural Network*), AlexNet, *Visual Geometry Group* (VGG), ResNet, Inception-ResNet-v2, FR-CNN, U-Net, DeeplabV3, *Pyramid scene parsing* (PsPnet), *Feature Pyramid Network* (FPN), Mask R-CNN melalui metode "*phrase searching*" untuk mencari informasi yang lebih spesifik dan dikombinasikan dengan Boolean Operator AND. Data, jurnal, dan artikel yang diperoleh akan disaring berdasarkan tahun publikasi dengan memprioritaskan 10 tahun terakhir, kesesuaian dengan kata kunci, tersedia *free full text*, dan kesesuaian dengan topik yang diangkat. Didapatkan sebanyak 6 artikel yang akan ditelusuri lebih lanjut untuk merangkum hasil penelitian dalam *literature review* ini.

PEMBAHASAN

Ulkus Dekubitus


Ulkus dekubitus merupakan luka pada kulit dan area di sekitarnya akibat tekanan terus-menerus dalam rentang waktu lama.^[5] Luka ini sering dijumpai pada tonjolan tulang beserta dengan perubahan warna dan kerusakan epidermis.^[9] Ulkus dekubitus diklasifikasikan menjadi kategori 1-4, *unstageable*, dan *deep tissue injury* (DTI).^[10] Permukaan kulit yang masih utuh tetapi terdapat *non-blanchable erythema*, hiperemi, dan perubahan warna disebut kategori 1. Perubahan warna bervariasi berdasarkan warna kulit pasien, tetapi tidak ada perubahan warna menjadi ungu atau merah marun. Sebelum perubahan warna muncul,

sudah terdapat perubahan pada temperatur dan kepadatan kulit. Kulit dapat terasa hangat atau dingin saat disentuh.^[11]

Kategori 2 terjadi pada lapisan epidermis dan dermis yang mulai terbuka dan nekrosis, serta ketebalan kulit menipis. Ulkus dangkal ini tampak mengkilap atau kering, berwarna merah atau merah muda, serta dapat disertai lepuh yang berisi cairan serum. Tidak ditemukan *slough* (jaringan mati kuning), *eschar* (jaringan mati hitam), dan jaringan granulasi.^[10-12] Ulkus kategori 3 meliputi jaringan subkutan dan hilangnya seluruh ketebalan kulit. Jaringan adiposa, jaringan granulasi, *slough*, dan *eschar* dapat tampak pada ulkus. Jika *slough* menutupi kedalaman ulkus, maka diklasifikasikan ke kategori *unstageable*. Tulang, tendon, dan otot belum tampak pada tahap ini. Kedalaman ulkus pada kategori ini bervariasi sesuai lokasi anatomi. Bagian tubuh dengan jaringan adiposa tebal dapat mengalami ulkus yang lebih dalam. *Malleolus*, pangkal hidung, oksiput, dan telinga tidak memiliki jaringan subkutan.^[12]

Ulkus pada kategori 4 disertai destruksi otot, tulang, dan tendon. Ulkus dapat menjalar ke otot, fascia, kapsul sendi, atau tendon sehingga meningkatkan risiko osteomielitis. Ketebalan kulit telah hilang sepenuhnya, sehingga tulang atau tendon dapat terlihat dan teraba langsung. *Slough* atau *eschar* juga tampak di sekitar ulkus.^[12] Ulkus dekubitus dinyatakan sebagai *unstageable* ketika seluruh jaringan sudah hilang tetapi ulkus ditutupi oleh *slough* atau *eschar* sehingga kedalaman ulkus tidak dapat ditentukan. *Slough* dan jaringan mati harus dibersihkan untuk menentukan kategori ulkus. DTI tampak seperti memar di bawah permukaan kulit yang utuh atau tidak utuh. Kulit mengalami perubahan warna menjadi ungu, marun, atau merah gelap dengan lepuh berisi darah. DTI muncul akibat gesekan dan tekanan dalam waktu jangka panjang.^[10,12]


Tabel 1. Kategori Ulkus Dekubitus^[12-13]

Kategori	Deskripsi	Gambar
1: Non-blanchable erythema	Kulit utuh dan terdapat perubahan warna atau kemerahan. Kulit terasa hangat atau dingin, serta disertai rasa nyeri dan kepadatan.	
2: Hilangnya sebagian ketebalan kulit	Lapisan epidermis dan dermis mulai terbuka. Ulkus tampak dangkal, mengkilap atau kering, berwarna merah atau merah muda, serta dapat disertai lepuh yang berisi cairan serum.	
3: Hilangnya seluruh ketebalan kulit	Mempengaruhi jaringan subkutan dan seluruh ketebalan kulit. Jaringan adiposa, jaringan granulasi, slough, dan eschar dapat tampak pada ulkus. Kedalaman ulkus bervariasi sesuai lokasi anatomi.	
4: Hilangnya seluruh ketebalan kulit dengan destruksi tulang, otot, atau tendon	Terdapat destruksi otot, tulang, dan tendon. Ketebalan kulit telah hilang sepenuhnya, sehingga tulang atau tendon dapat terlihat dan teraba langsung. Slough atau eschar juga tampak di sekitar ulkus.	
Unstageable	Seluruh jaringan sudah hilang tetapi ulkus ditutupi oleh slough atau eschar sehingga kedalaman ulkus tidak dapat ditentukan.	
Deep Tissue Injury (DTI)	Tampak seperti memar di bawah permukaan kulit yang utuh atau tidak utuh. Kulit mengalami perubahan warna menjadi ungu, marun, atau merah gelap dengan lepuh berisi darah.	

Patofisiologi Ulkus Dekubitus

Proses terbentuknya ulkus dekubitus dipengaruhi oleh berbagai faktor seperti tekanan, gesekan, gaya geser, kelembaban, dan mobilitas terbatas.^[13] Awal timbulnya ulkus dekubitus disebabkan oleh berat tubuh yang menekan kulit, terutama pada bagian tonjolan tulang. Tekanan kapiler arteri memiliki rentang normal 12-32 mmHg. Tekanan eksternal yang melebihi rentang tersebut akan menghambat aliran darah yang dapat berujung pada iskemia dan nekrosis jaringan. Saat ulkus pada kulit dapat ditemukan, maka jaringan sudah mengalami kerusakan yang ekstensif. Hal ini disebabkan karena bagian tubuh yang mengalami kerusakan jaringan paling awal adalah otot,

diikuti oleh jaringan subkutan, lalu terakhir pada kulit. Gesekan dan gaya geser yang timbul saat tubuh pasien berbaring pada tempat tidur juga berkontribusi terhadap kerusakan dan hipoksia jaringan.^[14] Pasien imobilisasi sering berada pada posisi setengah berbaring atau setengah duduk. Gravitasi menyebabkan tubuh cenderung ke bawah, sehingga timbul gesekan yang melawan arah gravitasi sehingga pasien tidak jatuh.^[14,15] Gesekan ini mengikis dan merusak lapisan stratum korneum. Bagian kulit yang lembab akan menimbulkan maserasi kulit dan mengubah pH kulit sehingga lebih kulit lebih rentan terhadap kerusakan.^[14] Faktor yang menimbulkan kelembaban yaitu inkontinensia urin, *diaphoresis*, dan drainase dari luka atau abses.^[13]



Gambar 1. Patofisiologi Ulkus Dekubitus^[15,17]

Komorbiditas juga mempengaruhi perkembangan ulkus dekubitus. Komorbiditas dan penyakit kronis paling sering ditemukan pada pasien dewasa dan lansia. Komplikasi tersebut biasanya disertai dengan keterbatasan fisik dan mobilitas. Penyakit kronis yang umum ditemukan seiring bertambahnya umur yaitu gangguan kardiovaskular, respirasi, ginjal, diabetes, dan neurodegeneratif. Gangguan kardiovaskular menyebabkan hipoperfusi, hipotensi, dan iskemia yang berperan dalam kerusakan jaringan dan pembentukan ulkus dekubitus. Gangguan respirasi menurunkan kadar oksigen sehingga terjadi hipoksia jaringan. Penggunaan alat seperti respirator dan kanul trakeostomi menimbulkan kompresi pada jaringan sekitar wajah dan leher. Gangguan ginjal kronis menyebabkan ketidakseimbangan homeostasis yang berujung pada anemia, kerusakan jaringan, dan mengganggu proses penyembuhan luka.^[16] Diabetes menurunkan respon sel dan *growth factor*, aliran darah, dan proses angiogenesis. Semua faktor tersebut menghambat proses penyembuhan luka.^[17] Penyakit neurodegeneratif seperti demensia dan parkinson menghambat fungsi motorik, sensorik dan kognitif yang menghambat mobilitas pasien.^[16]

Implementasi ML berupa CNN dalam Prediksi Ulkus Dekubitus

Ulkus dekubitus merupakan suatu penyakit yang menyebabkan seseorang

mengalami penurunan kualitas hidup, rasa nyeri, berkurangnya mobilitas, kerusakan pada bagian tubuh, dan depresi.^[18] Bahkan dalam prosesnya, seseorang yang mengalami ulkus dekubitus memiliki peluang yang lebih tinggi untuk mengalami suatu infeksi yang mengancam nyawa, keganasan, dan luka yang cenderung berulang. Luka yang terjadi pada ulkus dekubitus terbagi menjadi 4 tahap berdasarkan tingkat keparahannya. Dalam mengklasifikasikan suatu tingkat keparahan ulkus dekubitus memiliki tantangan secara klinis. Dalam sebuah studi mengatakan bahwa seseorang yang tergolong ke dalam klinisi *non-expert* hanya memiliki persentase sekitar 23% - 58% dalam mendeteksi secara tepat terhadap tingkat keparahan luka yang terjadi pada kasus ulkus dekubitus.^[19]

Pada perawat yang memiliki pelatihan medis yang minim atau tidak sama sekali akan mengalami kesulitan ketika melakukan proses *staging* pada luka ulkus dekubitus. Mayoritas perawat kembali menggunakan penilaian visual yang kurang tepat. Hal ini akan meningkatkan adanya hasil yang kurang tepat, komplikasi berupa infeksi, perawatan jangka panjang, dan rasa tidak nyaman. Oleh karena itu, teknologi dalam manajemen suatu luka memiliki peran yang sangat penting dalam proses perawatan luka kronis, termasuk ulkus dekubitus.^[20]

Hadirnya sebuah metode dengan menerapkan teknologi *computer vision* untuk memonitoring suatu proses penyembuhan luka secara akurat sangat dibutuhkan.^[21–23] Sebuah teknik baru menggunakan prinsip

cara kerja deteksi objek dan segmentasi kini mulai diaplikasikan, yakni alat yang dapat secara akurat menentukan lokasi cedera akibat tekanan dan juga bisa menentukan tingkat atau *staging* suatu luka ulkus dekubitus. Alat tersebut adalah *Convolutional Neural Network* (CNN). CNN dapat menggolongkan jenis jaringan yang berbeda, granulasi, jaringan nekrosis, dan permukaan yang mengalami pengelupasan dalam ulkus dekubitus sehingga dapat menggolongkan tingkat keparahan luka.^[20] Dalam sebuah studi oleh Kim Y *et al.* pada tahun 2014 dan Xiao C *et al.* pada tahun 2018 menyatakan bahwa CNN mencapai kesuksesan sebagai model tunggal dalam proses klasifikasi suatu gambar dan teks. Dalam prosesnya, CNN telah digunakan dalam penggambaran medis untuk mengklasifikasikan lesi otak atau mengklasifikasikan penyakit Alzheimer dengan akurasi 98.8%.^[24–26]

Mekanisme Kerja Sistem Konvolusi CNN dalam Image-Analysis Ulkus Dekubitus

Convolutional Neural Networks (CNN) mampu mengklasifikasikan gambar dua dimensi pada kategori tertentu melalui pengenalan pola. Algoritma ini mampu mengidentifikasi pola dan fitur penting dari suatu data tanpa pengawasan manusia.^[27] CNN dapat menganalisis suatu gambar melalui 4 lapisan. Pada lapisan pertama, gambar yang dimasukkan ke CNN akan diproses oleh *convolutional layer*. CNN memproses suatu gambar sebagai kumpulan angka yang disebut matriks. Setiap angka atau nilai pada gambar disebut sebagai sebuah piksel atau titik.^[28] Gambar tersebut kemudian disusun menjadi tinggi x panjang x kedalaman ($m \times m \times r$), dengan ukuran tinggi dan panjang yang sama.^[27] Pada lapisan ini, terdapat 3 komponen, yaitu *filter kernel*, *stride*, dan *padding*. *Kernel* memiliki ukuran dimensi yang sama dengan gambar yang dimasukkan, tetapi memiliki nilai parameter yang lebih kecil. Filter ini merupakan matriks yang umumnya berukuran 3×3 .^[28,29] *Stride* merupakan parameter yang menghitung jumlah pergeseran *kernel* yang diperlukan untuk menghasilkan *output*.^[29] *Kernel* akan bergeser pada setiap piksel di gambar dan menghitung konvolusinya, yaitu penjumlahan dari perkalian setiap titik atau piksel dengan setiap *kernel*. Perhitungan ini akan menghasilkan suatu nilai tunggal. Nilai-nilai ini merupakan *output* yang disebut *feature map*.^[27] *Padding* merupakan proses penambahan ukuran piksel terutama pada batas-batas gambar.^[29] Pada setiap proses konvolusi, informasi mengenai batas gambar cenderung menghilang dan ukuran gambar mengecil. *Padding* berfungsi untuk

meningkatkan ukuran gambar dan ukuran *feature map*.^[27]

Lapisan kedua disebut *pooling layer*. Fungsi utama dari lapisan ini adalah mengurangi jumlah parameter pada *feature map*. Ukuran *feature map* yang terlalu besar akan dikecilkan, tetapi informasi yang penting tetap dipertahankan pada setiap tahap *pooling*.^[28] Proses ini mengkombinasikan dua *convolutional layer* secara berurutan. Kombinasi ini menghasilkan nilai optimal dan mengurangi *overfitting*. Lapisan ketiga disebut *fully connected (FC) layer*. Lapisan ini umumnya terletak pada akhir dari struktur CNN. Hasil dari *pooling* atau *convolutional layer* sebelumnya dimasukkan pada *FC layer* dalam bentuk vektor. Tahap ini disebut *flattening*. Proses ini menghubungkan semua *neuron* dengan *neuron* pada lapisan sebelumnya sehingga menyerupai suatu jaringan saraf.^[27–29] Lapisan terakhir disebut *nonlinearity layer* (fungsi aktivasi). Lapisan ini berfungsi untuk menentukan hasil terakhir dari CNN. *Rectified Linear Unit* (ReLU) merupakan fungsi aktivasi yang paling sering digunakan.^[28]

Potensi Penerapan CNN-ML terhadap Diagnosis Ulkus Dekubitus

Kemampuan *image-analysis* yang dimiliki oleh ML berupa CNN sudah banyak diterapkan dalam dunia medis. Salah satunya dalam usaha diagnosis penyakit yang ditegakkan melalui analisis terhadap pencitraan atau penggambaran lokasi *on-site* penyakit.^[28,29] Dalam ulkus dekubitus, penegakan diagnosis sering dilakukan melalui visualisasi klinis yang membutuhkan bantuan teknologi dalam akurasinya.^[21–23] Penelitian-penelitian sudah memanfaatkan CNN dalam berbagai aplikasi, seperti AlexNet, VGG, ResNet, Inception-ResNet-v2, FR-CNN, U-Net, DeeplabV3, PsPnet, FPN, dan Mask R-CNN untuk memprediksi dan mendiagnosis ulkus dekubitus secara akurat.

Akurasi dan Algoritma AlexNet, VGG, ResNet, Inception-ResNet-v2 dalam Pressure Ulcer Assessment System (PUAS)

Pressure Ulcer Assessment System (PUAS) merupakan sistem yang dirancang menggunakan tipe algoritma dengan 2 langkah *sorting* menggunakan CNN-ML. Langkah *sorting* pertama mengklasifikasikan gambar patologis ulkus dekubitus berdasarkan temuan selulitis dan eritema. Langkah *sorting* kedua mengidentifikasi keberadaan jaringan nekrosis pada ulkus yang terbagi menjadi 3 kategori, yaitu

extensive, *moderate*, dan *limited* berdasarkan luas lesi nekrosis yang ditemukan. Langkah *sorting* disertai juga dengan pertanyaan klinis yang membantu pendekatan diagnosis. Setelah melewati dua tahap *sorting* tersebut, didapatkan 6 kategori tipe ulkus dekubitus berdasarkan tingkat keparahan dan tata cara manajemen.^[8]

Pengembangan PUAS dibantu dengan sistem CNN-ML yang telah dievaluasi dari berbagai model *software*, seperti AlexNet^[30], VGG^[31], ResNet^[32], dan Inception-ResNet-v2^[33]. Dari 4 macam model tersebut, peneliti melakukan proses *training* dan *learning* pada setiap model menggunakan 528 sampel gambar yang telah dikonfirmasi dan diklasifikasikan sesuai pembagian 6 kategori PUAS oleh tiga orang klinisi bedah plastik. Dari 528 sampel gambar kasus ulkus dekubitus tersebut, 327 sampel digunakan untuk fase *training* dari model CNN, sedangkan 201 sampel digunakan untuk *validating test*.^[8]

Hasil evaluasi menemukan nilai *F1-score* yang paling tinggi dari klasifikasi

eritema dan nekrosis diraih oleh model CNN Inception-ResNet-v2 (0,941 dan 0,935). Efektivitasnya dalam klasifikasi keberadaan eritema memiliki angka *accuracy* 98,5%, *precision* 97,7%, dan *recall* 95,5%. Di sisi lain, dalam pengelompokan tingkat nekrosis jaringan, PUAS memiliki angka *accuracy* sebesar 94,8% dengan angka *recall* dan *precision* sebesar 94,7% dan 92,4%. Bahkan, dalam fase *training*, PUAS Inception-ResNet-v2 memiliki skor F1 yang lebih tinggi dibandingkan *labelling* oleh tiga klinisi bedah plastik (0,940 VS 0,806). Fase validasi menunjukkan angka *F1-score* yang hampir sama antara evaluasi oleh PUAS menggunakan Inception-ResNet-v2 dengan tiga klinisi bedah plastik (0,94 VS 0,93). Hasil data tersebut menunjukkan bahwa kemampuan PUAS dalam kategorisasi dan diagnosis ulkus dekubitus sangat efektif, spesifik, dan sensitif.^[8]

Tabel 2. Analisis Akurasi AlexNet, VGG, ResNet, dan Inception-ResNet-v2 dalam Prediksi dan Diagnosis Ulkus Dekubitus.^[8]

The erythema classification task				
	Recall	Precision	Accuracy	F1-score
AlexNet	68.9%	71.2%	71.2%	0.700
VGG19 (19-layer)	86.4%	85.0%	86.4%	0.857
ResNet 50 (50-layer)	98.3%	81.7%	88.8%	0.892
Inception-ResNet-V2	88.9%	100.0%	99.4%	0.941
The necrotic tissue classification task				
	Recall	Precision	Accuracy	F1-score
AlexNet	78.1%	78.7%	78.0%	0.784
VGG19 (19-layer)	83.7%	83.2%	83.5%	0.834
ResNet 50 (50-layer)	91.9%	92.6%	92.2%	0.922
Inception-ResNet-V2	94.7%	92.4%	94.8%	0.935

CNN, convolutional neural network; VGG, Visual Geometry Group.

Akurasi dan Algoritma U-Net, DeeplabV3, PsPnet, FPN, dan Mask R-CNN dalam Deteksi Segmentasi Luka dan Ulkus Jaringan

Penilaian terhadap segmentasi luka dan regenerasi *epithelium* diterapkan dalam penelitian yang menggunakan beberapa jenis ML. Selain dari itu, penilaian terhadap karakteristik luka pada ulkus dekubitus dilakukan dengan bantuan metode *Simple Linear Iterative Clustering* (SLIC).^[34] Hasil

yang didapatkan terdapat dua model klasifikasi terhadap ulkus dekubitus, yaitu model klasifikasi berdasarkan segmentasi, ukuran dan keberadaan *re-epithelium*, serta model klasifikasi berdasarkan SLIC yang menggambarkan area *slough*, *eschar*, dan *granulasi*. Model klasifikasi segmentasi dan *re-epithelium* membutuhkan 2893 sampel gambar dalam proses *training*, sedangkan model klasifikasi karakteristik luka dengan metode SLIC membutuhkan 2836 sampel gambar.^[35]

Tabel 3. Analisis Akurasi U-Net, DeepLabV3, PsPnet, FPN, dan Mask R-CNN dalam Deteksi Segmentasi dan Temuan *re-epithelium*.

	IoU score	F1 score	Precision	Recall	Accuracy	Loss
U-Net	0.9745	0.9867	0.9868	0.9867	0.9911	0.0132
DeepLabV3	0.9782	0.9887	0.9888	0.9887	0.9925	0.0112
PsPnet	0.9211	0.9404	0.9317	0.9494	0.9780	0.0595
FPN	0.8196	0.8939	0.8556	0.9492	0.9346	0.1061
Mask R-CNN	0.8597	0.8456	0.8345	0.8542	0.8533	0.3742

Tabel 4. Analisis Akurasi U-Net, DeepLabV3, PsPnet, FPN, dan Mask R-CNN dalam Deteksi Karakteristik Luka Ulkus Dekubitus.

	IoU score	F1 score	Precision	Recall	Accuracy	Loss
U-Net	0.9830	0.9905	0.9913	0.9897	0.9899	0.0094
DeepLabV3	0.9834	0.9915	0.9915	0.9915	0.9957	0.0084
PsPnet	0.9390	0.9753	0.9614	0.9897	0.9899	0.0094
FPN	0.8252	0.9014	0.8615	0.9507	0.9508	0.0986
Mask R-CNN	0.7886	0.8480	0.9191	0.7871	0.8903	0.2032

Model *software* CNN yang digunakan dalam penelitian ini terbagi menjadi U-Net, DeeplabV3, PsPnet, FPN, dan Mask R-CNN. Dari 5 macam model CNN tersebut, masing-masing menerapkan deteksi terhadap segmentasi dan *re-epithelium*, serta deteksi terhadap karakteristik luka ulkus. Melalui penelitian tersebut, ditemukan performa dari DeeplabV3 melewati dari model-model CNN lainnya, baik dari deteksi segmentasi – *re-epithelium* dan deteksi karakteristik luka ulkus dengan nilai *F1-score* 0,9887 dan 0,9915. Dibandingkan dengan model CNN yang terburuk adalah Mask R-CNN dikarenakan memiliki nilai *F1-score* rendah pada dua model deteksi, baik pada deteksi segmentasi – *re-epithelium* dan deteksi karakteristik luka ulkus (0,8456 dan 0,8480). Hal ini terjadi karena Mask R-CNN memiliki sistem segmentasi tersendiri yang tidak mampu membedakan jaringan dengan granulasi dan *slough*.^[35]

SIMPULAN

Diantara berbagai model CNN-ML (*Convolutional Neural Network-Machine Learning*) yang memiliki efektivitas lebih baik adalah DeeplabvNet dan inception-ResNet-v2 berdasarkan atas skor *F1* yang cukup tinggi. *F1 score* menyatakan rata-rata antara presisi dan *recall*. Semakin tinggi nilai *F1* maka akan semakin tinggi akurasi dalam mengklasifikasikan suatu gambar, khususnya lesi pada ulkus dekubitus. Akurasi ini akan membantu tenaga kesehatan di dalam memprediksi, mendiagnosis, dan segmentasi terhadap ulkus dekubitus.

Namun dalam menilai efektivitas suatu alat berbasis CNN-ML diperlukan parameter dan pengembangan lainnya sehingga dapat menemukan suatu alat yang benar-benar memiliki akurasi yang baik untuk mendiagnosis dan melakukan segmentasi pada lesi ulkus dekubitus.

SARAN

Diharapkan model aplikasi CNN-ML berupa DeeplabvNet dan inception-ResNet-v2 dapat mulai dikembangkan di berbagai negara, khususnya Indonesia. Hal ini akan menjadi sebuah kemajuan di bidang teknologi medis yang memiliki peran vital untuk mencegah mortalitas pada kasus ulkus dekubitus. Penerapan model ini tentunya perlu melibatkan kesadaran dan peran dari berbagai pihak sehingga dapat diterapkan secara maksimal di Indonesia.

DAFTAR PUSTAKA

1. Källman U, Hommel A, Borgstedt Risberg M, Gunningberg L, Sving E, Bååth C. Pressure ulcer prevalence and prevention interventions – A ten-year nationwide survey in Sweden. *Int Wound J* 2022;19(7):1736–47.
2. Jiang M, Ma Y, Guo S, Jin L, Lv L, Han L, et al. Using machine learning technologies in pressure injury management: systematic review. *JMIR Med Informatics* 2021;9(3):1–10.
3. Li Z, Lin F, Thalib L, Chaboyer W. Global prevalence and incidence of pressure injuries in hospitalised adult patients: A systematic review and meta-analysis. *Int J Nurs Stud* 2020;105:103546.
4. Krishnawati D, Faidah N, Purwandari NP. PENGARUH PERUBAHAN POSISI TERHADAP KEJADIAN DECUBITUS PADA PASIEN TIRAH BARING DI RUANG IRIN RUMAH SAKIT MARDI RAHAYU KUDUS. *TSCD3Kep J* 2022;7(1).
5. Getie A, Bayle A, Bante A, Geda B, Mesfin F. Pressure ulcer prevention practices and associated factors among nurses in public hospitals of Harari regional state and Dire city

- administration, Eastern Ethiopia. *PLoS One* 2020;15(12 December):1–14.
6. Huang C, Ma Y, Wang C, Jiang M, Yuet Foon L, Lv L, et al. Predictive validity of the braden scale for pressure injury risk assessment in adults: A systematic review and meta-analysis. *Nurs Open* 2021;8(5):2194–207.
7. Pei J, Guo X, Tao H, Wei Y, Zhang H, Ma Y, et al. Machine learning-based prediction models for pressure injury: A systematic review and meta-analysis. *Int Wound J* 2023;20(10):4328–39.
8. Liu TJ, Christian M, Chu Y chia, Chen Y chun, Chang C wei, Lai F, et al. ScienceDirect A pressure ulcers assessment system for diagnosis and decision making using convolutional neural networks. *J Formos Med Assoc* 2022;121(11):2227–36.
9. Amirsyah M, Amirsyah M, Ikhlas M, Putra A. Ulkus Dekubitus pada Penderita Stroke Mirnasari. *J Kesehat Cegahum* 2020;2(3):1–8.
10. Fergus P, Chalmers C, Henderson W, Roberts D, Waraich A. Pressure Ulcer Categorization and Reporting in Domiciliary Settings Using Deep Learning and Mobile Devices: A Clinical Trial to Evaluate End-to-End Performance. *IEEE Access* 2023;11(July):65138–52.
11. Edsberg L, Black J, Goldberg M, McNichol L, Moore L, Sieggreen M. Revised National Pressure Ulcer Advisory Panel Pressure Injury Staging System Revised Pressure Injury Staging System. *J Wound Ostomy Cont Nurs* 2016;43(6):585–97.
12. Torello A. Schachner and Hansen's Textbook of Pediatric Dermatology. In: Schachner and Hansen's Textbook of Pediatric Dermatology. JP Medical Publishers; 2022. halaman 1608.
13. Phillips R. PRESSURE ULCERS: PATHOGENESIS AND CLINICAL FINDINGS. Calgary Guid.2018;
14. Mervis JS, Phillips TJ. Pressure ulcers : Pathophysiology , epidemiology , risk factors , and presentation. *J Am Dermatology* 2022;81(4):881–90.
15. Mamoto N, Gessal J. Rehabilitasi medik pada pasien geriatri ulkus decubitus. *J Med dan Rehabil* 2018;01(01):32–7.
16. Jaul E, Barron J, Rosenzweig JP, Menczel J. An overview of comorbidities and the development of pressure ulcers among older adults. *BMC Geriatr* 2018;18(305).
17. Lenche N, Katerina D, Nikolchev A, Lidija P, Biljana P zovic, Milenko K. The influence of comorbidity on the prevalence of pressure ulcers in geriatric patients. *Glob Dermatology* 2016;3(3):319–22.
18. Swerdlow M, Guler O, Yaakov R, Armstrong DG. Simultaneous Segmentation and Classification of Pressure Injury Image Data Using Mask-R-CNN. *Comput Math Methods Med* 2023;(3858997,).
19. Tschannen D, Mckay M, Steven M. Improving Pressure Ulcer Staging Accuracy Through a Nursing Student Experiential Intervention. *J Nurs Educ* 2016;55(5):266–70.
20. Zahia S, Zapirain MBG, Sevillano X, Gonzalez A, Kim PJ, Elmaghraby A. Tissue classification and segmentation of pressure injuries using convolutional neural networks. *Comput Methods Programs Biomed* 2019;159:51–8.
21. Mehl AA, Schneider Jr B, Schneider FK, Carvalho BHK. Measurement of wound area for early analysis of the scar predictive factor. *Rev Latino-Americana Enfer magem* 2020;28(e3299).
22. Cassidy B, Reeves ND, Pappachan JM, Gillespie D, Shea CO, Rajbhandari S, et al. The DFUC 2020 Dataset: Analysis Towards Diabetic Foot Ulcer Detection. *touchREVIEWS Endocrinol* 2021;17:2021.
23. Mazhar A, Huyvetter KD, Murphy GA, Jett S, Cuccia DJ, Modulim DGA. Noninvasive mapping of hemoglobin microcirculation using spatial frequency domain imaging in patients with history of limb complications who have undergone revascularization. *J Vasc Surg* 2020;72(1):e67.
24. L'opez-Zorrilla A, Serradilla-casado O, de Velasco-V'azquez M, Roa-Barco L, Grana M, Chyzyk D, et al. Brain White Matter Lesion Segmentation with 2D / 3D CNN Brain White Matter Lesion Segmentation. *Nat Artif Comput Nat Artif Comput* 2017;10337:394–403.
25. Kamnitsas K, Ledig C, Newcombe VFJ, Simpson JP, Kane AD, Menon DK, et al. Efficient multi-scale 3D CNN with fully connected CRF for accurate brain lesion segmentation. *Med Image Anal* 2017;36:61–78.
26. Farooq A, Anwar SM, Awais M, Rehman S. A deep CNN based multiclass classification of Alzheimer's disease using MRI. *IEEE Conf Im aging Syst* 2017;111–6.
27. Alzubaidi L, Zhang J, Humaidi AJ, Dujaili A Al, Duan Y, Shamma O Al, et al. Review of deep learning : concepts , CNN architectures , challenges , applications , future directions. *J Big Data* 2021;8(53):1–74.
28. Purwono, Ma'arif A, Rahmaniar W,

- Imam H, Fathurrahman K, Zatu A, et al. Understanding of Convolutional Neural Network (CNN): A Review. *Int J Robot Control Syst* 2022;2(4):739–48.
29. Affifah DD, Permanasari Y, Respitawulan. Teknik Konvolusi pada Deep Learning untuk Image Processing. In: *Bandung Conference Series: Mathematics*. 2022. halaman 103–12.
 30. Krizhevsky A, Sutskever I, Hinton GE. ImageNet classification with deep convolutional neural networks. *Commun ACM* 2017;60(6):84–90.
 31. Simonyan K, Zisserman A. Very deep convolutional networks for large-scale image recognition. *3rd Int Conf Learn Represent ICLR 2015 - Conf Track Proc* 2015;1–14.
 32. Sun KHXZSRJ. Deep Residual Learning for Image Recognition Kaiming. *Proc IEEE Conf Comput Vis Pattern Recognit* 2016;45(8):1951–4.
 33. Längkvist M, Karlsson L, Loutfi A. Inception-v4, Inception-ResNet and the Impact of Residual Connections on Learning. *Pattern Recognit Lett [Internet]* 2014;42(1):11–24. Available from: <http://arxiv.org/abs/1512.00567>
 34. Zhang J, Aviles-Rivero AI, Heydecker D, Zhuang X, Chan R, Schönlieb CB. Dynamic spectral residual superpixels. *Pattern Recognit [Internet]* 2021;112:107705. Available from: <https://www.sciencedirect.com/science/article/pii/S0031320320305082>
 35. Chang CW, Christian M, Chang DH, Lai F, Liu TJ, Chen YS, et al. Deep learning approach based on superpixel segmentation assisted labeling for automatic pressure ulcer diagnosis. *PLoS One [Internet]* 2022;17(2 February):1–19. Available from: <http://dx.doi.org/10.1371/journal.pone.0264139>