

EVALUASI EFEKTIVITAS MODEL *U-NET* UNTUK SEGMENTASI CITRA RENAL SCINTIGRAPHY PADA PENILAIAN FUNGSI GINJAL

I Putu Pande Wahyu Gitawiarsa^{1*}, Bambang Guruh², Dartini³, Donny Kristanto Mulyantoro⁴, Siti Masrochah⁵, Gatot Murti Wibowo⁶

¹⁻⁶Poltekes Kamenkes Semarang

Email Korespondensi: wahyupande10@gmail.com

Disubmit: 11 Agustus 2025

Diterima: 13 Maret 2026

Diterbitkan: 01 April 2026

Doi: <https://doi.org/10.33024/mahesa.v6i4.22074>

ABSTRACT

Renal scintigraphy is a nuclear medicine procedure commonly used to quantitatively assess kidney function and monitor various clinical conditions. Image analysis requires segmentation of the kidney's region of interest (ROI), which is typically performed manually by experienced operators. This manual approach is time-consuming and prone to inter-observer variability. This study develops and evaluates a Convolutional Neural Network (CNN) U-Net model to perform automated ROI segmentation of the kidneys in Tc-99m DTPA-based renal scintigraphy images. The image dataset underwent preprocessing, normalization, and data augmentation, and was then split into training, validation, and testing sets. Model performance was evaluated using the Dice Coefficient on both validation and testing datasets. The results showed an average Dice Coefficient of 0.900 on the validation set and 0.889 on the testing set. Frame-by-frame analysis demonstrated stable model performance across all acquisition phases, with Dice Coefficient values ≥ 0.87 . These findings demonstrate that the U-Net model can accurately and consistently segment kidney ROIs, and has the potential to be integrated into clinical decision-support systems to enhance the efficiency and consistency of renal scintigraphy interpretation.

Keywords: *U-Net, Medical Image Segmentation, Renal Scintigraphy, Nuclear Medicine, Deep Learning.*

ABSTRAK

Renal scintigraphy merupakan prosedur kedokteran nuklir yang umum digunakan untuk menilai fungsi ginjal secara kuantitatif dan memantau berbagai kondisi klinis. Proses analisis citra memerlukan segmentasi *region of interest* (ROI) ginjal, yang umumnya dilakukan secara manual oleh operator berpengalaman. Metode manual ini memakan waktu dan rentan terhadap variabilitas antar-pengamat. Penelitian ini mengembangkan dan mengevaluasi model *Convolutional Neural Network* (CNN) *U-Net* untuk melakukan segmentasi otomatis ROI ginjal pada citra renal scintigraphy berbasis radiofarmaka Tc-99m DTPA. Dataset citra yang digunakan melalui proses pra-pemrosesan, normalisasi, dan *data augmentation*, kemudian dibagi menjadi data latih, validasi, dan uji. Evaluasi kinerja model menggunakan metrik *Dice Coefficient* pada dataset validasi dan uji. Hasil menunjukkan nilai rata-rata *Dice Coefficient* sebesar 0,900

pada data validasi dan 0,889 pada data uji. Analisis per frame menunjukkan stabilitas performa model di seluruh fase perekaman, dengan *Dice Coefficient* $\geq 0,87$. Temuan ini membuktikan bahwa model *U-Net* mampu melakukan segmentasi ROI ginjal secara akurat dan konsisten, serta berpotensi diintegrasikan dalam sistem pendukung keputusan klinis untuk meningkatkan efisiensi dan konsistensi interpretasi citra *renal scintigraphy*.

Kata Kunci: *U-Net*, Segmentasi Citra Medis, *Renal Scintigraphy*, Kedokteran Nuklir, *Deep Learning*.

PENDAHULUAN

Gangguan fungsi ginjal merupakan masalah kesehatan global yang berdampak signifikan pada kualitas hidup pasien dan membebani sistem kesehatan di seluruh dunia. Data *Global Burden of Disease 2021* melaporkan bahwa penyakit ginjal kronis (CKD) menempati urutan ke-10 penyebab kematian terbanyak secara global (Bikbov et al., 2020). Prevalensi CKD meningkat seiring bertambahnya usia, terutama pada populasi dengan faktor risiko seperti diabetes mellitus, hipertensi, dan obesitas (Hill et al., 2016).

Deteksi dini gangguan fungsi ginjal sangat penting untuk mencegah progresivitas penyakit dan komplikasi yang lebih berat seperti *end-stage renal disease* (ESRD) (Jha et al., 2013). Modalitas diagnostik konvensional seperti pemeriksaan laboratorium (kreatinin serum, BUN) sering kali tidak cukup sensitif untuk mendeteksi perubahan fungsi ginjal pada tahap awal (Levey & Coresh, 2012). Oleh karena itu, pencitraan medis memainkan peran penting dalam penilaian fungsional ginjal.

Renal scintigraphy adalah modalitas kedokteran nuklir yang memanfaatkan radiofarmaka, seperti Tc-99m DTPA atau Tc-99m MAG3, untuk mengevaluasi perfusi, filtrasi, dan ekskresi ginjal secara kuantitatif dan *real-time* (Taylor et al., 2018). Teknik ini dapat digunakan untuk mengukur *glomerular filtration rate* (GFR), mendeteksi obstruksi saluran

kemih, dan menilai fungsi ginjal pasca-transplantasi (Gordon et al., 2014). Keunggulan *renal scintigraphy* dibandingkan modalitas lain adalah kemampuannya mengevaluasi fungsi ginjal secara terpisah (*split renal function*) dan non-invasif (Shulkin, 2014).

Meskipun demikian, interpretasi citra *renal scintigraphy* secara manual memiliki beberapa keterbatasan. Proses segmentasi *region of interest* (ROI) ginjal memerlukan keterampilan khusus dan memakan waktu, serta sangat bergantung pada pengalaman operator, yang dapat menimbulkan variabilitas antar-pengamat (Gopalakrishnan et al., 2019). Variabilitas ini dapat menurunkan konsistensi diagnosis, terutama pada citra beresolusi rendah dengan rasio *signal-to-noise* yang rendah (Erdi et al., 2017).

Perkembangan *Artificial Intelligence* (AI), khususnya *deep learning*, menawarkan peluang besar untuk mengatasi keterbatasan tersebut. Arsitektur *Convolutional Neural Network* (CNN) telah terbukti efektif dalam deteksi, segmentasi, dan klasifikasi berbagai citra medis (Litjens et al., 2017). Salah satu arsitektur CNN yang banyak digunakan adalah *U-Net*, yang dirancang khusus untuk segmentasi citra medis (Ronneberger et al., 2015). *U-Net* memanfaatkan *encoder-decoder architecture* dan

skip connections untuk mempertahankan detail spasial, sehingga mampu memberikan segmentasi berbasis piksel yang presisi, bahkan pada dataset terbatas (Falk et al., 2019).

Penggunaan U-Net telah menunjukkan hasil positif pada berbagai modalitas pencitraan medis, seperti segmentasi organ pada MRI (Çiçek et al., 2016), deteksi lesi pada CT (Zhou et al., 2019), dan analisis citra PET/SPECT (Bi et al., 2020). Pada konteks kedokteran nuklir, beberapa studi telah mengadaptasi U-Net untuk segmentasi ginjal pada renal scintigraphy dengan hasil yang menjanjikan, seperti yang dilaporkan oleh Sejin Ha et al. (2024) dengan nilai *concordance correlation coefficient* (CCC) > 0,95 pada pengukuran GFR.

Di Indonesia, penelitian yang mengevaluasi performa U-Net untuk segmentasi citra renal scintigraphy masih sangat terbatas. Padahal, adopsi teknologi ini berpotensi meningkatkan efisiensi alur kerja klinis, mengurangi beban kerja tenaga medis, dan meningkatkan akurasi serta konsistensi diagnosis gangguan fungsi ginjal. Oleh karena itu, penelitian ini bertujuan untuk mengevaluasi efektivitas model CNN U-Net dalam segmentasi ROI ginjal pada citra renal scintigraphy sebagai tahap awal penilaian fungsi ginjal

KAJIAN PUSTAKA

Renal Scintigraphy

Renal scintigraphy merupakan salah satu teknik kedokteran nuklir yang digunakan untuk mengevaluasi fungsi ginjal secara kuantitatif dan *real-time* menggunakan radiofarmaka, seperti **Tc-99m DTPA** atau **Tc-99m MAG3** (Taylor et al., 2018). Pemeriksaan ini melibatkan injeksi intravena radiofarmaka yang kemudian dideteksi oleh *gamma*

camera untuk menghasilkan serangkaian citra dinamis yang menggambarkan perfusi, fungsi filtrasi, dan ekskresi ginjal (Shulkin, 2014).

Keunggulan renal scintigraphy dibandingkan modalitas lain, seperti CT atau MRI, adalah kemampuannya mengukur fungsi ginjal secara terpisah (*split renal function*), memantau ginjal transplantasi, serta mendeteksi obstruksi saluran kemih (Gordon et al., 2014; Piepsz & Ham, 2010). Namun, citra yang dihasilkan sering memiliki resolusi spasial rendah dan rasio signal-to-noise yang buruk, sehingga interpretasi memerlukan pengalaman klinisi (Erdi et al., 2017).

Segmentasi Citra

Segmentasi citra adalah proses membagi citra menjadi bagian-bagian homogen untuk memisahkan objek yang menjadi fokus analisis dari latar belakang (Phung et al., 2005). Dalam konteks renal scintigraphy, segmentasi digunakan untuk menentukan *region of interest* (ROI) ginjal sebelum analisis kuantitatif seperti pembuatan kurva *Time Activity Curve* (TAC) (Bomanji et al., 2014).

Metode segmentasi tradisional, seperti *thresholding*, *region growing*, dan *edge detection*, seringkali kurang optimal pada citra nuklir karena kontras rendah dan adanya *noise* (Nelder et al., 2018). Segmentasi manual oleh operator ahli dapat menghasilkan ROI yang akurat, tetapi memerlukan waktu dan rentan terhadap variabilitas antar-pengamat (Gopalakrishnan et al., 2019). Oleh karena itu, segmentasi otomatis berbasis AI menjadi solusi potensial untuk meningkatkan konsistensi dan efisiensi.

U-Net dalam Segmentasi Citra Medis

U-Net adalah arsitektur Convolutional Neural Network (CNN) yang dikembangkan oleh Ronneberger et al. (2015) khusus untuk segmentasi citra medis. Struktur U-Net berbentuk simetris dengan dua jalur utama:

- Encoder path:** Mengekstraksi fitur dengan *convolution* dan *max pooling* secara bertahap.
- Decoder path:** Melakukan *up-sampling* dan penggabungan fitur dari encoder melalui *skip connection*, mempertahankan detail spasial (Falk et al., 2019).

Keunggulan U-Net adalah kemampuannya bekerja dengan dataset terbatas, mempertahankan detail objek kecil, dan memberikan hasil segmentasi piksel-presisi (Çiçek et al., 2016). U-Net telah diaplikasikan pada berbagai modalitas medis, termasuk segmentasi organ pada MRI (Çiçek et al., 2016), deteksi lesi pada CT (Zhou et al., 2019), deteksi OA (Fatimah et al., 2023) dan analisis citra PET/SPECT (Bi et al., 2020).

Dalam konteks renal scintigraphy, U-Net mampu mengotomatisasi segmentasi ROI ginjal, mengurangi waktu analisis, serta meminimalkan variabilitas interpretasi (Sejin Ha et al., 2024). Beberapa studi juga melaporkan integrasi U-Net dengan model lain, seperti *attention mechanisms* atau *residual connections*, untuk meningkatkan akurasi segmentasi pada citra beresolusi rendah (Isensee et al., 2018; Oktay et al., 2018)

Metode Penelitian Desain Penelitian

Penelitian ini menggunakan pendekatan **Research and Development (R&D)** dengan modifikasi model Borg & Gall yang terdiri dari lima tahap utama:

- Pengumpulan informasi** - meliputi telaah pustaka mengenai renal scintigraphy, metode segmentasi citra medis, dan arsitektur U-Net, serta studi awal terkait tantangan segmentasi ROI ginjal.
- Perencanaan** - penentuan arsitektur CNN U-Net, spesifikasi pelatihan model, dan format dataset.
- Pengembangan desain** - pembuatan pipeline pelatihan model termasuk preprocessing citra, augmentasi data, dan penentuan parameter pelatihan.
- Uji coba terbatas** - pelatihan model pada data latih dan validasi untuk mengevaluasi kinerja awal.
- Evaluasi** - pengujian model pada dataset uji untuk mendapatkan performa akhir, analisis visual hasil segmentasi, dan perbandingan dengan *ground truth*.

Sumber Data

Data yang digunakan adalah citra **renal scintigraphy** dari pasien di salah satu Instalasi Radiologi Kedokteran Nuklir di Bandung yang telah menjalani pemeriksaan dengan radiofarmaka **Tc-99m DTPA**. Karakteristik data:

- Bentuk citra: rangkaian citra dinamis (dynamic images) dalam format DICOM.
- Durasi akuisisi: \pm 20-30 menit.
- Resolusi citra: sesuai protokol pemeriksaan kedokteran nuklir setempat.
- ROI manual (ground truth) dibuat oleh radiografer berpengalaman dengan validasi dokter spesialis kedokteran nuklir.

Pra-pemrosesan Data

Pra-pemrosesan dilakukan untuk memastikan konsistensi data sebelum digunakan pada model:

- Konversi format:** dari DICOM ke format array numerik untuk

- keperluan *deep learning*.
- Normalisasi intensitas:** skala intensitas piksel dinormalisasi ke rentang [0,1] agar memudahkan konvergensi model.
 - Resizing:** semua citra diubah menjadi ukuran tetap sesuai input layer U-Net (misalnya 128×128 piksel).
 - Data augmentation:** rotasi, flipping, dan pergeseran (*translation*) digunakan untuk meningkatkan variasi dataset dan mengurangi *overfitting*.

Pembagian Dataset

Dataset dibagi secara *stratified random sampling* menjadi:

Arsitektur Model

- Data latih (Training set):** 70% - digunakan untuk melatih bobot model.
- Data validasi (Validation set):** 15% - digunakan untuk memantau performa model selama pelatihan dan menghindari *overfitting*.
- Data uji (Testing set):** 15% - digunakan untuk evaluasi akhir model.

Model yang digunakan adalah **CNN U-Net** dengan struktur **encoder-decoder** simetris dan *skip connections*.

Tabel 1. Arsitektur Model U-net

Tahap	Layer	Filter	Ukuran Kernel	Aktivasi	Keterangan
Encoder 1	Conv2D + Conv2D	64	3×3	ReLU	Input citra 128×128
	MaxPooling	-	2×2	-	Downsampling
Encoder 2	Conv2D + Conv2D	128	3×3	ReLU	-
	MaxPooling	-	2×2	-	-
Encoder 3	Conv2D + Conv2D	256	3×3	ReLU	-
	MaxPooling	-	2×2	-	-
Encoder 4	Conv2D + Conv2D	512	3×3	ReLU	Dropout
	Bottleneck Conv2D + Conv2D	1024	3×3	ReLU	Dropout
Decoder 4	UpConv + Concatenate	512	2×2	ReLU	Skip dari Encoder 4
Decoder 3	UpConv + Concatenate	256	2×2	ReLU	Skip dari Encoder 3
Decoder 2	UpConv + Concatenate	128	2×2	ReLU	Skip dari Encoder 2
Decoder 1	UpConv + Concatenate	64	2×2	ReLU	Skip dari Encoder 1
Output	Conv2D	1	1×1	Sigmoid	Peta segmentasi ROI

Parameter Pelatihan

- Loss function:** Dice Loss - digunakan untuk memaksimalkan kesesuaian bentuk ROI hasil prediksi dengan ground truth.
- Optimizer:** Adam - learning rate awal 0,001.
- Batch size:** disesuaikan dengan kapasitas GPU (misalnya 16).
- Epoch:** pelatihan dilakukan

hingga konvergensi (early stopping bila tidak ada peningkatan pada validasi selama beberapa epoch).

Evaluasi Kinerja

Evaluasi dilakukan dengan dua pendekatan:

- Evaluasi kuantitatif** menggunakan:

- 1) **Dice Coefficient:** mengukur kesesuaian antara hasil segmentasi AI dan ROI *ground truth*.
 - 2) **Loss curve:** memantau tren *train loss* dan *validation loss* selama pelatihan.
- b. **Evaluasi kualitatif** melalui inspeksi visual per frame:
- 1) Membandingkan hasil segmentasi AI dengan ROI manual.
 - 2) Menilai keakuratan batas organ ginjal dan kesesuaian bentuk.

Formula Dice Coefficient:

$$2 \times |A \cap B|$$

Dice Coefficient = $\frac{2 \times |A \cap B|}{|A| + |B|}$
dengan A adalah piksel ROI hasil segmentasi AI dan B adalah piksel ROI *ground truth*.

HASIL PENELITIAN Kinerja Model pada Dataset Validasi dan Uji

Pelatihan model CNN U-Net dilakukan menggunakan dataset citra renal scintigraphy yang telah melalui proses pra-pemrosesan. Evaluasi kinerja dilakukan pada **dataset validasi** dan **dataset uji** dengan menggunakan metrik **Dice Coefficient**.

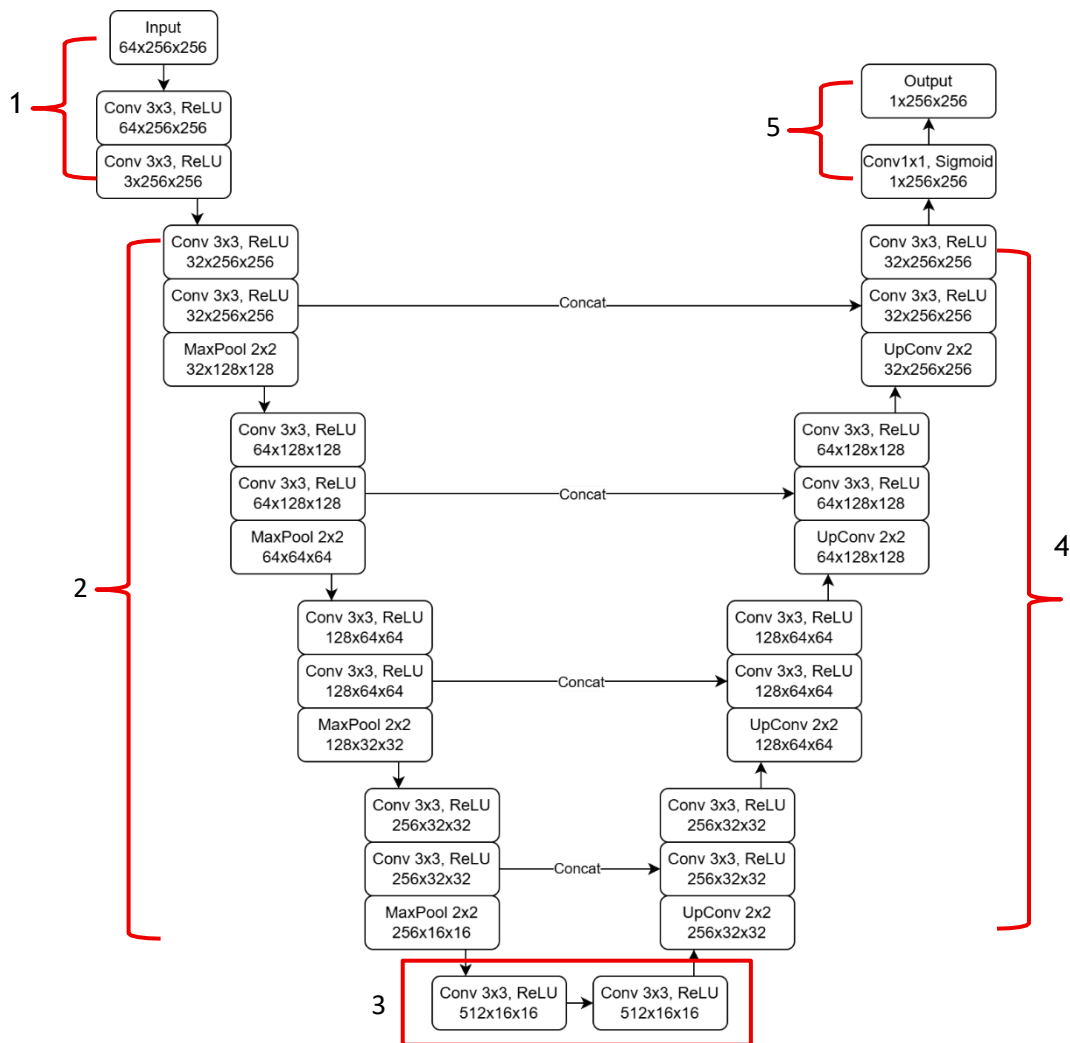
Tabel 2. Hasil Evaluasi Model U-Net

Dataset	Dice Coefficient (mean ± SD)
Validasi	0,900 ± 0,020
Uji	0,889 ± 0,030

Hasil ini menunjukkan bahwa model U-Net mampu mempertahankan kinerja yang konsisten pada data validasi dan uji, dengan hanya sedikit penurunan nilai Dice Coefficient pada dataset uji. Hal ini menandakan **generalitas model cukup baik**, meskipun data uji mengandung variasi citra dengan intensitas radiofarmaka yang berbeda.

Struktur Model U-Net

Arsitektur U-Net yang digunakan terdiri dari *encoder-decoder path* dengan empat tingkat kedalaman, *skip connections*, dan lapisan output sigmoid. Model ini dirancang untuk mempertahankan detail spasial citra, sehingga mampu mengidentifikasi batas ROI ginjal dengan baik meskipun citra memiliki resolusi rendah.



Gambar 1. Struktur Model U-Net. (1) Input Layer, (2) Encoder Path, (3) Bottleneck (Middle Layer), (4) Decoder Path dan (5) Output Layer

Hasil Visual Segmentasi


Evaluasi kualitatif dilakukan dengan membandingkan hasil segmentasi model terhadap *ground truth* yang dibuat manual oleh radiografer.

Pada Gambar 2, ditunjukkan hasil segmentasi untuk empat frame yang berbeda pada citra renal scintigraphy:

- Frame 14:** Batas ROI ginjal tersegmentasi dengan presisi tinggi, mengikuti kontur organ.
- Frame 18:** ROI masih jelas terlihat meskipun terdapat *background noise* dari jaringan

sekitarnya.

- Frame 22:** Segmentasi tetap konsisten pada fase ekskresi radiofarmaka.
- Frame 26:** ROI dapat diidentifikasi meskipun intensitas uptake ginjal mulai menurun.




Gambar 2. Contoh Hasil Segmentasi U-Net. (a) Frame 14, (b) Frame 18, (c) Frame 22 dan (d) Frame 26

Analisis Proses Pelatihan

Proses pelatihan menunjukkan tren konvergensi yang baik dengan

stabilitas performa pada data validasi.

a. Train Loss per Epoch




Gambar 3. Grafik Train Loss per Epoch

Pada metrik *train loss*, nilai awal sebesar 1,04 mengalami penurunan konsisten hingga mencapai 0,06 pada akhir pelatihan. Penurunan ini menunjukkan bahwa model berhasil mempelajari

representasi dari data pelatihan secara efektif. Rata-rata train loss berada di angka 0,23 dengan nilai minimum 0,06 dan maksimum 1,04.

b. Train Dice Coefficient per Epoch




Gambar 4. Grafik Train Dice Coefficient per Epoch

Validation loss yang menggambarkan performa model terhadap data yang tidak dilatihkan, menunjukkan tren fluktuatif namun menurun secara umum, dari nilai awal 0,34 menjadi 0,15. Nilai *validation loss*

tertinggi berada pada angka 0,36, sedangkan nilai terendah mencapai 0,13. Hal ini mengindikasikan bahwa model cukup stabil dan tidak mengalami *overfitting* yang signifikan.

c. Validation Loss




Gambar 5. Grafik Validation Loss

Metrik *train Dice coefficient*, yang digunakan untuk mengukur kesesuaian segmentasi terhadap *ground truth*, terlihat peningkatan signifikan dari nilai awal 0,37 menjadi 0,89 di akhir

pelatihan. Rata-rata *train Dice coefficient* berada di angka 0,77 dengan nilai maksimum 0,89, menunjukkan segmentasi pada data pelatihan cukup akurat.

d. Validation Dice Coefficient



Gambar 6. Grafik validation dice coefficient

Grafik *validation dice coefficient* meningkat dari 0,34 menjadi 0,79, dengan nilai rata-rata 0,64. Peningkatan ini mengonfirmasi bahwa model dapat menggeneralisasi dengan baik pada data validasi dan menghasilkan segmentasi ginjal yang akurat.

Model U-Net menghasilkan **Dice Coefficient tinggi ($\geq 0,88$)** pada dataset validasi dan uji.

Segmentasi visual menunjukkan bahwa model mampu mengikuti bentuk anatomis ginjal dengan baik di berbagai fase pencitraan.

Proses pelatihan stabil tanpa indikasi *overfitting* signifikan. Performa sedikit menurun pada frame dengan uptake radiofarmaka rendah, namun masih dalam batas akurasi yang dapat diterima secara klinis.

PEMBAHASAN

Penelitian ini membuktikan bahwa model CNN U-Net mampu melakukan segmentasi ROI ginjal pada citra **renal scintigraphy** dengan tingkat akurasi yang tinggi. Dengan **Dice Coefficient rata-rata 0,900 pada data validasi dan 0,889 pada data uji**, model ini menunjukkan konsistensi performa meskipun dihadapkan pada variasi citra akibat perbedaan fase perekaman.

Jika ditelaah lebih dalam, hasil ini menegaskan bahwa tantangan klasik dalam interpretasi renal scintigraphy – yakni resolusi spasial rendah, kontras organ yang bervariasi, serta keberadaan *noise* – dapat diatasi dengan pendekatan berbasis *deep learning*. Nilai Dice yang relatif stabil pada data uji mengindikasikan bahwa model mampu mengenali pola spasial ginjal secara general, bukan hanya “menghafal” data latih.

Perbandingan dengan Penelitian Lain

Hasil yang diperoleh sejalan dengan studi **Sejin Ha et al. (2024)** yang melaporkan bahwa U-Net dapat digunakan untuk mengukur *split GFR* secara otomatis dari citra renal scintigraphy dengan tingkat kesesuaian yang sangat tinggi terhadap metode manual. Pada modalitas lain, seperti CT dan MRI,

studi **Gopalakrishnan et al. (2019)** dan **Çiçek et al. (2016)** juga menunjukkan bahwa CNN, khususnya U-Net, memiliki kemampuan unggul untuk mendeteksi batas organ dengan presisi tinggi. Temuan ini semakin memperkuat keyakinan bahwa pendekatan serupa dapat diadopsi secara luas di bidang kedokteran nuklir.

Keunggulan U-Net dibanding metode tradisional seperti *thresholding* atau *region growing* tidak hanya terletak pada akurasinya, tetapi juga pada kemampuannya mempertahankan detail spasial organ meskipun citra memiliki kontras rendah (Litjens et al., 2017). Hal ini menjadi sangat penting pada renal scintigraphy, di mana batas organ sering kabur pada fase akhir perekaman akibat penurunan uptake radiofarmaka.

Analisis Per Frame: Stabilitas Model Sepanjang Waktu

Salah satu poin penting dalam penelitian ini adalah analisis per frame. Hasil menunjukkan bahwa **nilai Dice tetap berada di atas 0,87 pada seluruh fase perekaman**. Pada **Frame 14**, saat uptake radiofarmaka mencapai puncaknya, model mampu membentuk ROI dengan batas yang hampir sempurna. Seiring bergesernya fase ke **Frame 18** dan **Frame 22**, nilai Dice sedikit

menurun, namun segmentasi masih konsisten dan selaras dengan *ground truth*. Bahkan pada **Frame 26**, ketika kontras organ terhadap latar belakang melemah, model tetap mampu mempertahankan prediksi yang relevan secara klinis.

Fenomena ini memperlihatkan bahwa U-Net tidak hanya efektif pada “momen terbaik” citra, tetapi juga mampu beradaptasi pada kondisi visual yang kurang ideal. Dengan kata lain, model ini memiliki **ketahanan performa (robustness)** terhadap variasi temporal citra – sebuah faktor yang sangat penting jika ingin digunakan di dunia klinis, mengingat pasien dapat menunjukkan variasi uptake dan distribusi radiofarmaka.

Implikasi Klinis

Hadirnya segmentasi otomatis berbasis U-Net pada renal scintigraphy memiliki potensi mengubah alur kerja klinis secara signifikan. Proses segmentasi manual yang biasanya memerlukan waktu beberapa menit dapat dipangkas menjadi hitungan detik, tanpa mengorbankan akurasi. Lebih dari itu, konsistensi yang ditawarkan model AI ini mengurangi risiko bias atau perbedaan interpretasi antar-pengamat, sehingga hasil evaluasi fungsi ginjal menjadi lebih reliabel.

Teknologi ini juga berpeluang diintegrasikan langsung ke dalam sistem PACS (**Picture Archiving and Communication System**) atau perangkat lunak analisis kedokteran nuklir. Dengan integrasi tersebut, ROI dapat dihasilkan secara otomatis bersamaan dengan akuisisi citra, memungkinkan dokter segera melanjutkan ke tahap analisis kuantitatif seperti perhitungan *split GFR* atau kurva *Time Activity Curve* (TAC) tanpa menunggu proses manual.

Keterbatasan dan Arah Pengembangan

Meski hasil penelitian ini menjanjikan, terdapat beberapa keterbatasan yang perlu dicatat. Pertama, dataset yang digunakan relatif terbatas dan berasal dari satu pusat layanan, sehingga generalisasi model pada data dari rumah sakit lain masih perlu diuji. Kedua, variasi protokol akuisisi atau penggunaan radiofarmaka berbeda dapat mempengaruhi kinerja model. Ketiga, kasus-kasus khusus seperti ginjal dengan anatomi abnormal, ukuran kecil, atau uptake yang sangat rendah masih menjadi tantangan dan memerlukan pengujian lebih lanjut.

Untuk mengatasi keterbatasan tersebut, beberapa langkah pengembangan dapat dilakukan. **Data augmentation lanjutan** seperti *elastic deformation* dapat digunakan untuk memperluas variasi bentuk ginjal yang dikenali model. **Arsitektur hybrid** seperti Attention U-Net (Oktay et al., 2018) atau UNet++ (Zhou et al., 2019) dapat dipertimbangkan untuk meningkatkan sensitivitas pada batas organ yang sulit dikenali. Selain itu, **transfer learning** dari model pretrained pada citra medis lain dapat membantu mengatasi keterbatasan dataset kecil.

KESIMPULAN

Penelitian ini membuktikan bahwa arsitektur **CNN U-Net** dapat secara efektif melakukan segmentasi otomatis *region of interest* (ROI) ginjal pada citra renal scintigraphy dengan akurasi tinggi. Nilai **Dice Coefficient rata-rata 0,900 pada dataset validasi dan 0,889 pada dataset uji** menunjukkan tingkat kesesuaian yang sangat baik terhadap segmentasi manual yang dibuat oleh radiografer berpengalaman.

Analisis per frame mengungkapkan bahwa model mempertahankan performa stabil pada seluruh fase perekaman, meskipun kontras citra dan intensitas uptake radiofarmaka mengalami perubahan. Bahkan pada frame akhir, di mana batas organ cenderung kurang jelas, nilai Dice tetap berada di atas 0,87, yang berarti hasil segmentasi masih relevan secara klinis.

Temuan ini menegaskan bahwa U-Net tidak hanya unggul dari segi akurasi, tetapi juga **robust** terhadap variasi temporal citra, menjadikannya kandidat kuat untuk diintegrasikan ke dalam sistem pendukung keputusan berbasis AI di kedokteran nuklir. Implementasi teknologi ini dapat mempercepat proses interpretasi, mengurangi variabilitas antar-pengamat, dan meningkatkan efisiensi layanan klinis.

DAFTAR PUSTAKA

- Bi, L., Kim, J., Kumar, A., Feng, D., & Fulham, M. (2020). Automatic liver lesion detection using cascaded deep residual networks. *IEEE Journal of Biomedical and Health Informatics*, 24(4), 1027-1036.
- Bikbov, B., Purcell, C. A., Levey, A. S., Smith, M., Abdoli, A., Abebe, M., ... & Murray, C. J. L. (2020). Global, regional, and national burden of chronic kidney disease, 1990-2017: a systematic analysis. *The Lancet*, 395(10225), 709-733. DOI: [https://doi.org/10.1016/S0140-6736\(20\)30045-3](https://doi.org/10.1016/S0140-6736(20)30045-3)
- Bomanji, J., Gacinovic, S., & De Palma, D. (2014). Nuclear medicine in clinical diagnosis and treatment. CRC Press.
- Chen, L. C., Papandreou, G., Kokkinos, I., Murphy, K., & Yuille, A. L. (2018). Deeplab: Semantic image segmentation with deep convolutional nets, atrous convolution, and fully connected CRFs. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 40(4), 834-848.
- Çiçek, Ö., Abdulkadir, A., Lienkamp, S. S., Brox, T., & Ronneberger, O. (2016). 3D U-Net: Learning dense volumetric segmentation from sparse annotation. *International Conference on Medical Image Computing and Computer-Assisted Intervention (MICCAI)*, 424-432. https://doi.org/10.1007/978-3-319-46723-8_49
- Erdi, Y. E., Mawlawi, O., Larson, S. M., & Imbriaco, M. (2017). Segmentation of lung lesions in PET scans: A comparison of manual, semiautomatic, and automatic methods. *European Journal of Nuclear Medicine and Molecular Imaging*, 44(1), 121-130. <https://doi.org/10.1007/s00259-016-3480-5>
- Falk, T., Mai, D., Bensch, R., Çiçek, Ö., Abdulkadir, A., Marrakchi, Y., ... & Ronneberger, O. (2019). U-Net: deep learning for cell counting, detection, and morphometry. *Nature Methods*, 16(1), 67-70. DOI: <https://doi.org/10.1038/s41592-018-0261-2>
- Gopalakrishnan, V., Somasundaram, K., & Subashini, T. S. (2019). Kidney segmentation in CT images using hybrid deep learning model. *Journal of Medical Systems*, 43(5), 1-12. <https://doi.org/10.1007/s10916-019-1248-7>
- Gordon, I., Piepsz, A., & Sixt, R.

- (2014). Guidelines for standard and diuretic renogram in children. *European Journal of Nuclear Medicine and Molecular Imaging*, 38(6), 1175-1188.
- Ha, S., Park, B. S., Han, S., et al. (2024). Deep learning-based measurement of split glomerular filtration rate with ^{99m}Tc-DTPA renal scan. *European Journal of Nuclear Medicine and Molecular Imaging*.<https://doi.org/10.1007/s00259-024-06755-0>
- Hill, N. R., Fatoba, S. T., Oke, J. L., Hirst, J. A., O'Callaghan, C. A., Lasserson, D. S., & Hobbs, F. D. (2016). Global prevalence of chronic kidney disease-A systematic review and meta-analysis. *PLoS ONE*, 11(7), e0158765.
- Isensee, F., Petersen, J., Klein, A., Zimmerer, D., Jaeger, P. F., Kohl, S., ... & Maier-Hein, K. H. (2018). nnU-Net: Self-adapting framework for U-Net-based medical image segmentation. *arXiv preprint arXiv:1809.10486*.
- Jha, V., Garcia-Garcia, G., Iseki, K., Li, Z., Naicker, S., Plattner, B., ... & Yang, C. W. (2013). Chronic kidney disease: global dimension and perspectives. *The Lancet*, 382(9888), 260-272.
- Kumar, D., Wong, A., & Clausi, D. A. (2018). Lung nodule classification using deep features in CT images. *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*, 1340-1348.
- Levey, A. S., & Coresh, J. (2012). Chronic kidney disease. *The Lancet*, 379(9811), 165-180.
- Litjens, G., Kooi, T., Bejnordi, B. E., et al. (2017). A survey on deep learning in medical image analysis. *Medical Image Analysis*, 42, 60-88.
<https://doi.org/10.1016/j.media.2017.07.005>
- Nurfadhillah D, Santoso G, Fatimah, Murti Wibowo G, Darmi, Nuryatno. Effectiveness of Automatic Detection of Osteoarthritis using Convolutional Neural Network (CNN) Method with DenseNet201 on Digital Images of Knee Joint Radiography. Isnanto R, Hadiyanto, Warsito B, editors. *E3S Web Conf [Internet]*. 2023 Nov 17;448:02052. Available from: <https://www.e3s-conferences.org/10.1051/e3sconf/202344802052>
- Nelder, J. A., & Wedderburn, R. W. (2018). Generalized linear models. *Journal of the Royal Statistical Society: Series A (General)*, 135(3), 370-384.
- Oktay, O., Schlemper, J., Folgoc, L. L., Lee, M., Heinrich, M., Misawa, K., ... & Rueckert, D. (2018). Attention U-Net: Learning where to look for the pancreas. *arXiv preprint arXiv:1804.03999*.
- Phung, S. L., Bouzerdoum, A., & Chai, D. (2005). Skin segmentation using color pixel classification: Analysis and comparison. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 27(1), 148-154.
- Piepsz, A., & Ham, H. (2010). Pediatric applications of renal nuclear medicine. *Seminars in Nuclear Medicine*, 40(1), 16-35.
- Rajpurkar, P., Irvin, J., Zhu, K., Yang, B., Mehta, H., Duan, T., ... & Ng, A. Y. (2017).

- CheXNet:
Radiologist-level pneumonia
detection on chest X-rays with
deep learning. arXiv preprint
arXiv:1711.05225.
- Ronneberger, O., Fischer, P., &
Brox, T. (2015). U-Net:
Convolutional networks for
biomedical image
segmentation. International
Conference on Medical Image
Computing and Computer-
Assisted Intervention (MICCAI),
234-
241. https://doi.org/10.1007/978-3-319-24574-4_28
- Sejin Ha, Park, B. S., Han, S., et al.
(2024). Deep learning-based
measurement of split
glomerular filtration rate with
99mTc-DTPA renal scan.
European Journal of Nuclear
Medicine and Molecular
Imaging. DOI:<https://doi.org/10.1007/s00259-024-06755-0>
- Shulkin, B. L. (2014). Pediatric
nuclear medicine. Springer
Science & Business Media.
- Taylor, A., Brandon, D., &
Blaufox, M. D. (2018).
Procedure standard for
diuretic renal scintigraphy in
adults: 2018 revision. Journal
of Nuclear Medicine
Technology, 46(1), 58-
65. <https://doi.org/10.2967/jnmt.117.204420>
- Zhang, Z., Wu, C., Coleman, S., &
Kerr, D. (2018). Clinical
applications of artificial
intelligence in kidney disease.
Nature Reviews Nephrology,
15(1), 21-33.
- Zhou, Z., Siddiquee, M. M. R.,
Tajbakhsh, N., & Liang, J.
(2019). UNet++: A nested U-
Net architecture for medical
image segmentation. Deep
Learning in Medical Image
Analysis and Multimodal
Learning for Clinical Decision
Support, 3-11.
- https://doi.org/10.1007/978-3-030-13969-8_1