

Pengembangan Sistem Informasi Deteksi Dini Penyakit Ginjal Kronis Berbasis Web dengan TabNet

DOI: <http://dx.doi.org/10.35889/progresif.v22i2.3669>

Creative Commons License 4.0 (CC BY –NC)



Jessen Hero Pratama^{1*}, Genrawan Hoendarto²

¹Sistem Informasi, Universitas Widya Dharma Pontianak, Pontianak, Indonesia

²Informatika, Universitas Widya Dharma Pontianak, Pontianak, Indonesia

*e-mail *Corresponding Author*: 22412910_tania_aurelia@widyadharm.ac.id

Abstract

Chronic kidney disease is a global health problem that requires early detection to prevent the progression of more serious conditions. This study aims to design and implement a web-based early detection information system for chronic kidney disease integrated with a prediction model. The system was developed using the Prototyping method with TabNet as the classification model and Class-Conditional Conformal Prediction (CCP) to provide prediction confidence information. The study used secondary dummy data representing clinical attributes and risk factors for chronic kidney disease. Data were processed using median imputation, soft class weighting, and train-validation-calibration-test splitting. Prediction labels were determined using a CKD probability threshold of 0.75. Evaluation results showed accuracy of 0.8614, precision of 0.9448, recall of 0.9013, and F1-score of 0.9226. CCP enables the system to display a prediction set, making early detection results more informative and structured.

Keywords: *Chronic kidney disease; Conformal prediction; Early detection; Information systems; TabNet algorithm*

Abstrak

Penyakit ginjal kronis merupakan masalah kesehatan global yang memerlukan deteksi dini untuk mencegah perkembangan kondisi yang lebih serius. Penelitian ini bertujuan merancang dan mengimplementasikan sistem informasi deteksi dini penyakit ginjal kronis berbasis web yang terintegrasi dengan model prediksi. Sistem dikembangkan menggunakan metode Prototyping dengan TabNet sebagai model klasifikasi dan *Class-Conditional Conformal Prediction* (CCP) untuk menyajikan informasi keyakinan prediksi. Data penelitian menggunakan data sekunder berbentuk data dummy yang merepresentasikan atribut klinis dan faktor risiko penyakit ginjal kronis. Data diproses menggunakan median *imputation*, *soft class weighting*, dan pembagian *train-validation-calibration-test*. Label prediksi ditentukan berdasarkan threshold probabilitas CKD sebesar 0,75. Hasil pengujian menunjukkan *accuracy* 0,8614, *precision* 0,9448, *recall* 0,9013, dan *F1-score* 0,9226. Penerapan CCP memungkinkan sistem menampilkan prediction set, sehingga hasil deteksi dini menjadi lebih informatif dan terstruktur.

Kata kunci: *penyakit ginjal kronis; conformal prediction; deteksi dini; sistem informasi; algoritma TabNet*

1. Pendahuluan

Penyakit ginjal kronis merupakan salah satu masalah kesehatan global yang signifikan karena prevalensinya terus meningkat dan berdampak pada kematian, komorbiditas, serta beban layanan kesehatan [1]. Penyakit ini menjadi perhatian penting karena pada tahap awal sering kali tidak menunjukkan gejala yang jelas, sehingga banyak kasus baru teridentifikasi setelah kondisi pasien berkembang ke tahap yang lebih lanjut [2]. Keterlambatan diagnosis dapat meningkatkan risiko komplikasi, memperbesar kebutuhan intervensi medis, serta menambah beban biaya pelayanan kesehatan [3]. Oleh karena itu, deteksi dini penyakit ginjal kronis menjadi tema penting untuk diteliti karena dapat membantu proses identifikasi risiko secara lebih cepat, terstruktur, dan mudah diakses.

Dalam konteks pengelolaan data kesehatan, proses deteksi dini penyakit ginjal kronis membutuhkan sistem yang tidak hanya mampu mencatat data pasien, tetapi juga dapat mengelola data pemeriksaan, memproses hasil deteksi, menyimpan riwayat prediksi, dan menyajikan informasi pendukung bagi pengguna. Perkembangan teknologi informasi membuka peluang untuk membangun sistem berbasis web yang dapat membantu pengelolaan data medis secara lebih sistematis. Namun, dalam praktiknya, hasil deteksi dini tidak cukup hanya disajikan dalam bentuk label CKD atau non-CKD. Pengguna juga memerlukan informasi tambahan mengenai tingkat keyakinan prediksi agar hasil deteksi dapat diinterpretasikan secara lebih hati-hati, terutama karena kesalahan prediksi dalam konteks kesehatan dapat berdampak pada keterlambatan identifikasi risiko.

Beberapa penelitian terdahulu telah berupaya menyelesaikan permasalahan terkait deteksi, prediksi, dan pengelolaan penyakit ginjal kronis. Chinta et al. [3] meneliti pemanfaatan *point-of-care testing* dan teknologi kesehatan digital terintegrasi untuk mendukung skrining CKD pada populasi berisiko tinggi. Kanda et al. [5] mengembangkan sistem berbasis web dengan machine learning untuk memprediksi progresi penyakit ginjal kronis dan mortalitas pasien. Katz et al. [6] mengembangkan layanan konsultasi medis virtual berbasis web untuk pengelolaan CKD, hipertensi, dan diabetes secara terintegrasi. Selain itu, Pan dan Tong [7], Khalid et al. [8], serta Yoshizaki et al. [9] menunjukkan bahwa kecerdasan buatan dan machine learning memiliki potensi dalam mendukung prediksi penyakit ginjal kronis melalui evaluasi performa seperti akurasi, sensitivitas, spesifisitas, dan AUC. Meskipun demikian, sebagian besar penelitian tersebut masih lebih menekankan pada fungsi prediksi, skrining, atau layanan digital secara umum. Dengan demikian, masih terdapat gap berupa kebutuhan pengembangan sistem informasi deteksi dini CKD yang tidak hanya mengelola data dan menghasilkan prediksi, tetapi juga menyajikan informasi tingkat keyakinan prediksi sebagai pendukung interpretasi hasil.

Berdasarkan gap tersebut, penelitian ini mengusulkan pengembangan sistem informasi deteksi dini penyakit ginjal kronis berbasis web dengan mengintegrasikan model TabNet dan *Class-Conditional Conformal Prediction* (CCP). TabNet dipilih karena dirancang untuk mengolah data tabular melalui mekanisme *sequential attention*, sehingga mampu memilih fitur penting secara adaptif pada proses pembelajaran [10]. Sementara itu, CCP digunakan untuk menyajikan informasi tingkat keyakinan prediksi dan *prediction set*, sejalan dengan literatur medical AI yang menekankan pentingnya ketidakpastian prediksi dalam meningkatkan keandalan penggunaan kecerdasan buatan di bidang kesehatan [11], [12], [13]. Kebaruan penelitian ini terletak pada pengembangan sistem informasi kesehatan yang tidak hanya berfungsi sebagai media pengelolaan data dan prediksi, tetapi juga menyediakan keluaran yang lebih informatif melalui penyajian label klasifikasi, probabilitas CKD, *confidence score*, dan *prediction set*. Penelitian ini bertujuan untuk merancang, membangun, dan mengevaluasi sistem informasi deteksi dini penyakit ginjal kronis berbasis *web* yang terintegrasi dengan model TabNet dan CCP.

2. Metodologi

2.1 Tahapan Penelitian

Penelitian ini merupakan penelitian pengembangan atau *Research and Development* yang berfokus pada pembangunan sistem informasi deteksi dini penyakit ginjal kronis berbasis *web*. Metode pengembangan sistem yang digunakan adalah Prototyping, karena metode ini memungkinkan proses pengembangan dilakukan secara bertahap melalui analisis kebutuhan, perancangan awal, pembangunan prototipe, evaluasi, dan penyempurnaan sistem. Pendekatan ini sesuai digunakan dalam penelitian ini karena sistem yang dikembangkan tidak hanya berfungsi untuk mengelola data pasien dan data pemeriksaan, tetapi juga mengintegrasikan model prediksi untuk menghasilkan informasi deteksi dini penyakit ginjal kronis.

Tahapan penelitian meliputi analisis kebutuhan, perancangan prototipe, pembangunan sistem, evaluasi dan perbaikan prototipe, serta pengujian. Tahap analisis kebutuhan dilakukan untuk mengidentifikasi kebutuhan fungsional dan non-fungsional sistem, termasuk aktor pengguna, data masukan, proses prediksi, dan keluaran sistem. Tahap perancangan prototipe menghasilkan rancangan awal sistem yang mencakup alur proses, struktur data, antarmuka, serta integrasi model prediksi. Tahap pembangunan sistem dilakukan dengan mengimplementasikan rancangan ke dalam aplikasi *web* dan mengintegrasikan model TabNet serta *Class-Conditional Conformal Prediction* (CCP) ke dalam sistem. Selanjutnya, prototipe dievaluasi dan disempurnakan hingga diperoleh sistem akhir. Tahap terakhir adalah pengujian,

yang dilakukan melalui pengujian fungsional sistem dan pengujian performa model prediksi untuk menilai kemampuan sistem dalam mendukung deteksi dini penyakit ginjal kronis.

2.2 Analisis Kebutuhan Sistem

Analisis kebutuhan dilakukan untuk mengidentifikasi fungsi utama sistem, kebutuhan operasional, aktor pengguna, serta karakteristik data yang digunakan dalam pembangunan sistem informasi deteksi dini penyakit ginjal kronis. Tahap ini bertujuan memastikan bahwa sistem tidak hanya mampu melakukan prediksi, tetapi juga mendukung pengelolaan data pasien, data pemeriksaan, penyimpanan riwayat hasil deteksi, dan penyajian informasi deteksi dini secara terintegrasi.

Secara fungsional, sistem mencakup proses login, pengelolaan data pasien, pengelolaan data pemeriksaan, proses prediksi, penyimpanan dan pencarian riwayat prediksi, monitoring data, serta pencetakan laporan. Sistem juga menerapkan pembatasan hak akses berdasarkan peran pengguna, yaitu admin dan petugas, sehingga setiap pengguna hanya dapat mengakses fungsi sesuai dengan kebutuhan operasionalnya.

Dari sisi non-fungsional, sistem dikembangkan sebagai aplikasi *web* lokal yang terhubung dengan basis data secara terstruktur. Aspek non-fungsional yang diperhatikan meliputi kemudahan penggunaan, kecepatan respons sistem, keteraturan penyimpanan data, pembatasan hak akses pengguna, serta kemampuan sistem untuk terintegrasi dengan model prediksi.

Parameter *input* sistem berupa data klinis dan faktor risiko pasien, sedangkan *output* sistem berupa hasil klasifikasi deteksi dini penyakit ginjal kronis dalam kategori CKD atau non-CKD, disertai informasi tingkat keyakinan prediksi. Data penelitian menggunakan data sekunder berbentuk data *dummy* yang disusun berdasarkan atribut klinis dan faktor risiko penyakit ginjal kronis. Data tersebut digunakan untuk mendukung pengembangan, integrasi, dan pengujian awal sistem informasi. Dengan demikian, hasil evaluasi pada penelitian ini diposisikan sebagai pengujian performa sistem pada lingkungan data uji, bukan sebagai validasi klinis langsung terhadap pasien nyata. Penelitian ini menggunakan 23 fitur utama, yaitu Age, Gender, BMI, Smoking, PhysicalActivity, DietQuality, FamilyHistoryKidneyDisease, FamilyHistoryHypertension, FamilyHistoryDiabetes, PreviousAcuteKidneyInjury, UrinaryTractInfections, SystolicBP, DiastolicBP, FastingBloodSugar, HbA1c, SerumCreatinine, BUNLevels, GFR, ProteinInUrine, ACR, HemoglobinLevels, Edema, dan MedicationAdherence. Pemilihan fitur tersebut didasarkan pada keterkaitannya dengan karakteristik pasien, faktor risiko, dan indikator klinis penyakit ginjal kronis [14], [15], [16], [17].

Pada tahap praproses data, nilai kosong pada fitur numerik ditangani menggunakan teknik *median imputation*, yaitu mengisi nilai kosong menggunakan median dari masing-masing fitur. Teknik ini digunakan karena median lebih tahan terhadap pengaruh nilai ekstrem dibandingkan rata-rata. Selain itu, karena data penelitian memiliki distribusi kelas yang tidak seimbang, proses pelatihan model menggunakan *soft class weighting* untuk mengurangi kecenderungan model terhadap kelas mayoritas. Data kemudian dibagi menggunakan skema *train-validation-calibration-test*. Data *train* digunakan untuk melatih model TabNet, data *validation* digunakan untuk memantau proses pelatihan dan memilih konfigurasi model, data *calibration* digunakan dalam proses Class-Conditional Conformal Prediction (CCP) dengan skema *split calibration*, sedangkan data *test* digunakan untuk mengevaluasi kinerja model. Penentuan label klasifikasi dilakukan menggunakan pendekatan *threshold-based decision* dengan nilai ambang 0,75. Jika probabilitas CKD $\geq 0,75$, maka data diklasifikasikan sebagai CKD, sedangkan jika probabilitas CKD $< 0,75$, maka data diklasifikasikan sebagai non-CKD.

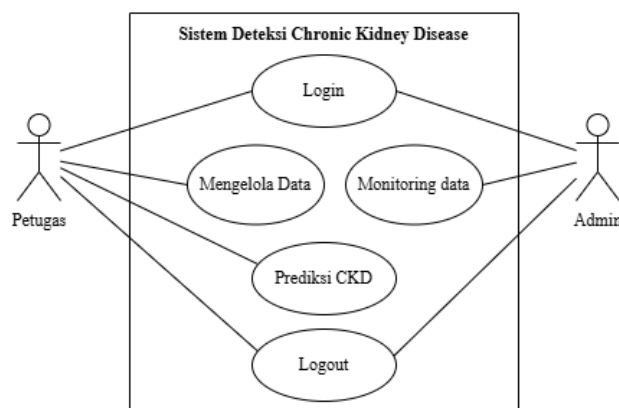
2.3 Perancangan dan Pembangunan Sistem

Perancangan dan pembangunan sistem dilakukan berdasarkan kebutuhan fungsional dan non-fungsional yang telah dianalisis sebelumnya. Tahap ini bertujuan menghasilkan sistem informasi deteksi dini penyakit ginjal kronis berbasis *web* yang mampu mengelola data pasien, data pemeriksaan, proses prediksi, penyimpanan riwayat hasil deteksi, monitoring data, dan pencetakan laporan secara terintegrasi.

Sistem dirancang dengan arsitektur berbasis *web* yang menghubungkan pengguna, aplikasi, basis data, dan modul prediksi. Pengguna berinteraksi melalui antarmuka *web* untuk memasukkan dan mengelola data. Data pemeriksaan yang tersimpan kemudian diproses oleh modul prediksi yang mengintegrasikan model TabNet dan CCP. Model TabNet digunakan untuk

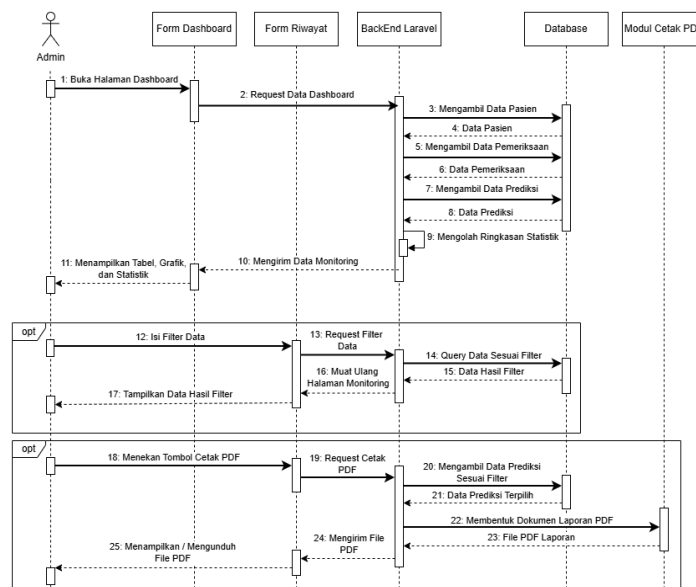
menghasilkan probabilitas klasifikasi CKD atau non-CKD, sedangkan CCP digunakan untuk memberikan informasi tingkat keyakinan prediksi. Hasil prediksi ditampilkan pada aplikasi dan disimpan sebagai riwayat prediksi.

Rancangan sistem divisualisasikan melalui diagram *use case*, diagram *sequence*, serta desain alur algoritma TabNet-CCP. Diagram *use case* digunakan untuk menggambarkan hubungan antara aktor admin dan petugas dengan fungsi utama sistem. Diagram *sequence* digunakan untuk menjelaskan alur monitoring data, mulai dari pengambilan data pasien, data pemeriksaan, dan data prediksi dari basis data, penyajian ringkasan statistik, proses filter data, hingga pencetakan laporan. Sementara itu, desain alur algoritma TabNet-CCP digunakan untuk menggambarkan proses prediksi, mulai dari praproses data, pemrosesan oleh model TabNet, penentuan label berdasarkan *threshold*, pembentukan *prediction set* melalui CCP, hingga penyajian hasil prediksi kepada pengguna.



Gambar 1. Diagram Use Case Sistem Deteksi Dini CKD

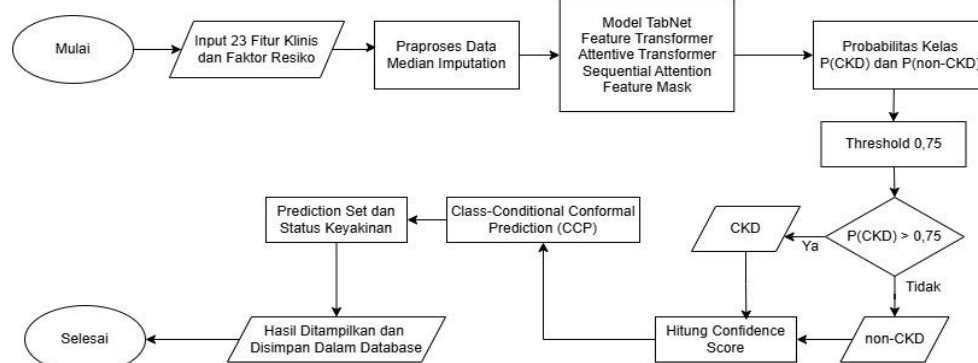
Gambar 1 menunjukkan diagram use case sistem deteksi dini CKD. Diagram ini menggambarkan dua aktor utama, yaitu admin dan petugas. Petugas berperan dalam mengelola data pasien, data pemeriksaan, menjalankan proses prediksi, dan melihat hasil deteksi dini. Admin berperan dalam melakukan monitoring, melihat riwayat prediksi, melakukan pencarian data, dan mencetak laporan. Pembagian peran ini menunjukkan bahwa sistem menerapkan kontrol akses berdasarkan kebutuhan pengguna.



Gambar 2. Diagram Sequence Monitoring Data

Diagram *sequence* pada Gambar 2 menunjukkan proses monitoring data pada sistem deteksi dini penyakit ginjal kronis. Diagram ini menggambarkan alur interaksi antara pengguna

(admin), antarmuka sistem, *backend*, basis data, dan modul pencetakan laporan. Proses dimulai ketika admin membuka halaman *dashboard* dan sistem mengirimkan permintaan data ke *backend*. *Backend* kemudian mengambil data pasien, data pemeriksaan, dan data prediksi dari basis data untuk selanjutnya diolah menjadi ringkasan statistik. Hasil pengolahan tersebut dikirim kembali ke antarmuka dan ditampilkan dalam bentuk tabel, grafik, dan statistik. Diagram ini juga menunjukkan bahwa sistem menyediakan fitur filter data dan pencetakan laporan. Ketika admin melakukan filter, sistem akan melakukan query ulang ke basis data sesuai parameter yang diberikan. Selain itu, ketika pengguna memilih untuk mencetak laporan, sistem akan mengambil data yang telah difilter dan membentuk dokumen PDF melalui modul cetak. Dengan demikian, proses monitoring tidak hanya bersifat pasif, tetapi juga mendukung interaksi pengguna dalam melakukan analisis data dan pelaporan hasil deteksi dini.



Gambar 3. Desain Alur Algoritma TabNet-CCP pada Sistem

Gambar 3 menunjukkan desain alur algoritma TabNet-CCP yang diterapkan dalam sistem. Data masukan berupa 23 fitur klinis dan faktor risiko pasien terlebih dahulu melalui tahap praproses, termasuk penanganan nilai kosong menggunakan *median imputation*. Data hasil praproses kemudian diproses oleh model TabNet. Pada tahap ini, TabNet menggunakan mekanisme *sequential attention* untuk memilih fitur yang relevan pada setiap tahap pengambilan keputusan melalui komponen *attentive transformer* dan *feature transformer*. Keluaran model berupa probabilitas kelas CKD dan non-CKD. Probabilitas CKD kemudian dibandingkan dengan *threshold* sebesar 0,75 untuk menentukan label prediksi. Selanjutnya, keluaran probabilitas model diproses menggunakan CCP untuk membentuk *prediction set* dan menghasilkan informasi keyakinan prediksi. Hasil akhir yang ditampilkan sistem meliputi label prediksi, probabilitas CKD, *confidence score*, *prediction set*, dan status keyakinan prediksi.

Selain perancangan proses sistem, tahap ini juga mencakup penggunaan TabNet sebagai model klasifikasi utama karena sesuai untuk pengolahan data tabular medis dan mampu melakukan pemilihan fitur secara adaptif. *Output* dari model TabNet berupa probabilitas kelas yang digunakan untuk menentukan label klasifikasi berdasarkan *threshold* sebesar 0,75. Untuk memberikan informasi tambahan mengenai tingkat keyakinan prediksi, keluaran model kemudian diproses menggunakan CCP.

CCP digunakan sebagai mekanisme kalibrasi pada keluaran model TabNet dengan melakukan kalibrasi secara terpisah pada masing-masing kelas. Pendekatan ini memungkinkan sistem menghasilkan ukuran keyakinan prediksi yang lebih sesuai dan informatif dalam mendukung proses deteksi dini.

Tahap pembangunan sistem dilakukan dengan mengimplementasikan seluruh rancangan tersebut ke dalam aplikasi *web* dan mengintegrasikan model TabNet serta modul CCP ke dalam sistem. Integrasi ini memungkinkan data pemeriksaan yang dimasukkan pengguna diproses langsung oleh model, kemudian menghasilkan keluaran deteksi dini yang dapat ditampilkan dan disimpan dalam sistem. Dengan demikian, hasil perancangan tidak berhenti pada model konseptual, tetapi diwujudkan menjadi sistem yang dapat digunakan untuk mendukung deteksi dini penyakit ginjal kronis secara terintegrasi.

2.4 Pengujian dan Analisis

Pengujian dilakukan untuk mengevaluasi performa model prediksi serta memastikan fungsi utama sistem berjalan sesuai dengan kebutuhan. Pengujian pada penelitian ini terdiri atas pengujian performa model, analisis keluaran CCP, dan pengujian fungsional sistem.

Pengujian performa model dilakukan menggunakan metrik evaluasi klasifikasi, yaitu *accuracy*, *precision*, *recall*, *F1-score*, *specificity*, *balanced accuracy*, dan ROC-AUC. Metrik tersebut digunakan untuk mengukur kemampuan model dalam mengklasifikasikan data uji ke dalam kategori penyakit ginjal kronis (CKD) dan non-CKD. Validasi hasil prediksi dilakukan dengan membandingkan label prediksi yang dihasilkan sistem terhadap label acuan pada data uji.

Setiap data uji diproses oleh model TabNet untuk menghasilkan probabilitas kelas CKD. Probabilitas tersebut kemudian dibandingkan dengan *threshold* sebesar 0,75. Jika probabilitas CKD $\geq 0,75$, maka data diklasifikasikan sebagai CKD, sedangkan jika probabilitas CKD $< 0,75$, maka data diklasifikasikan sebagai non-CKD. Hasil klasifikasi tersebut selanjutnya dibandingkan dengan label acuan untuk menentukan apakah prediksi termasuk benar atau salah.

Hasil perbandingan antara label prediksi dan label acuan dikelompokkan ke dalam empat kategori, yaitu True Positive, True Negative, False Positive, dan False Negative. True Positive menunjukkan data berlabel CKD yang diprediksi sebagai CKD, sedangkan True Negative menunjukkan data berlabel non-CKD yang diprediksi sebagai non-CKD. False Positive menunjukkan data berlabel non-CKD yang diprediksi sebagai CKD, sedangkan False Negative menunjukkan data berlabel CKD yang diprediksi sebagai non-CKD. Kategori tersebut digunakan untuk menyusun confusion matrix dan menghitung metrik evaluasi performa model.

Selain evaluasi klasifikasi, keluaran model juga dianalisis menggunakan Class-Conditional Conformal Prediction (CCP). CCP digunakan untuk memberikan informasi tambahan berupa tingkat keyakinan prediksi dan *prediction set* berdasarkan keluaran probabilitas model serta data kalibrasi. Melalui mekanisme ini, sistem tidak hanya menampilkan hasil klasifikasi CKD atau non-CKD, tetapi juga menunjukkan apakah hasil prediksi memiliki tingkat keyakinan yang tinggi atau masih memerlukan verifikasi lebih lanjut. Analisis terhadap keluaran CCP dilakukan untuk menilai kontribusi informasi keyakinan prediksi dalam mendukung interpretasi hasil deteksi dini.

Pengujian fungsional sistem dilakukan secara terbatas menggunakan pendekatan *black box testing*. Pengujian ini bertujuan memastikan fitur utama sistem, seperti login, pengelolaan data pasien, pengelolaan data pemeriksaan, proses prediksi, riwayat prediksi, monitoring data, dan pencetakan laporan, berjalan sesuai kebutuhan.

Accuracy digunakan untuk mengukur proporsi prediksi yang benar terhadap seluruh data, yang dirumuskan sebagai berikut:

$$Accuracy = \frac{TP + TN}{TP + TN + FP + FN} \tag{1}$$

Precision digunakan untuk mengukur tingkat ketepatan prediksi positif, yang dirumuskan sebagai:

$$Precision = \frac{TP}{TP + FP} \tag{2}$$

Recall digunakan untuk mengukur kemampuan model dalam mendeteksi data positif, yang dirumuskan sebagai:

$$Recall = \frac{TP}{TP + FN} \tag{3}$$

F1-score merupakan rata-rata harmonis antara *precision* dan *recall*, yang dirumuskan sebagai:

$$F1-Score = 2 \times \frac{Precision \times Recall}{Precision + Recall} \tag{4}$$

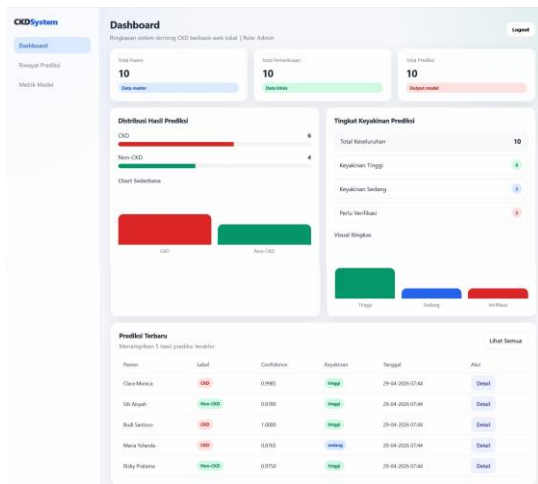
Selain empat metrik utama tersebut, penelitian ini juga menggunakan *specificity*, *balanced accuracy*, dan ROC-AUC sebagai metrik tambahan untuk melihat kemampuan model dalam mengenali kelas non-CKD dan kemampuan diskriminasi model secara keseluruhan.

3. Hasil dan Pembahasan

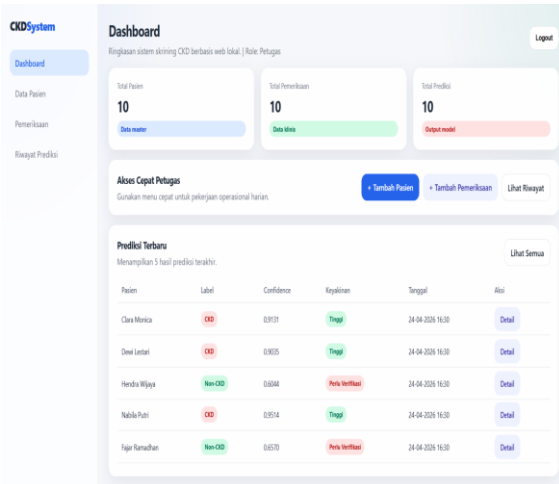
3.1 Implementasi Antarmuka Sistem

Hasil implementasi penelitian ini berupa sistem informasi deteksi dini penyakit ginjal kronis berbasis *web* yang mendukung dua peran pengguna, yaitu admin dan petugas.

Perbedaan peran diimplementasikan melalui pembatasan hak akses dan perbedaan menu pada antarmuka sistem. Dengan mekanisme ini, setiap pengguna dapat mengakses fungsi sesuai kebutuhan operasionalnya, sehingga proses pengelolaan data, deteksi dini, monitoring, dan pelaporan dapat dilakukan secara lebih terstruktur.

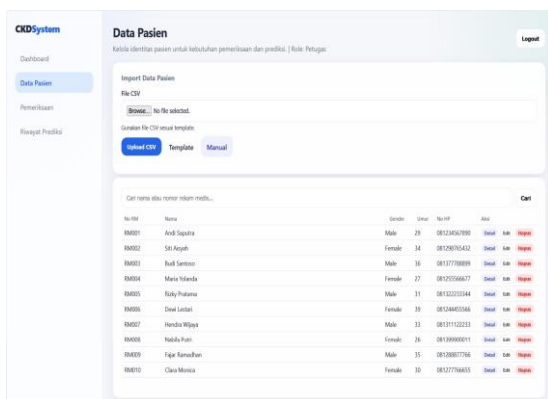


Gambar 4. Dashboard Admin

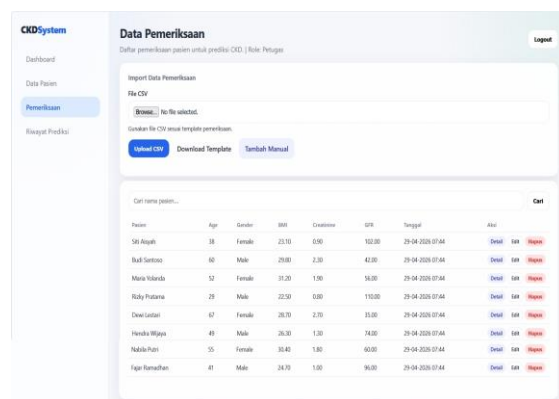


Gambar 5. Dashboard Petugas

Dashboard admin pada Gambar 4 digunakan untuk mendukung fungsi monitoring sistem. Halaman ini menampilkan ringkasan jumlah pasien, jumlah pemeriksaan, jumlah prediksi, distribusi hasil prediksi, tingkat keyakinan prediksi, serta daftar prediksi terbaru. Sementara itu, *dashboard* petugas pada Gambar 5 menampilkan informasi ringkasan dan akses cepat untuk kegiatan operasional, seperti penambahan data pasien, penambahan data pemeriksaan, dan akses ke riwayat prediksi. Perbedaan tampilan ini menunjukkan bahwa sistem telah menerapkan kontrol akses berbasis peran.

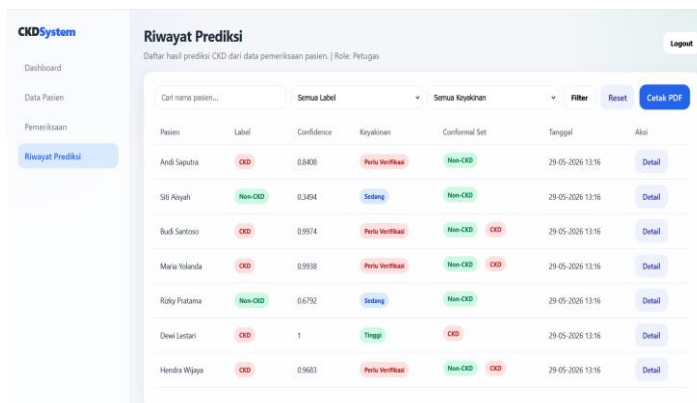


Gambar 6. Data Pasien



Gambar 7. Data Pemeriksaan

Halaman data pasien pada Gambar 6 digunakan untuk mengelola identitas pasien sebagai data master dalam sistem. Fitur yang tersedia meliputi pencarian data, penambahan data pasien, serta aksi detail, edit, dan hapus. Halaman data pemeriksaan pada Gambar 7 digunakan untuk mengelola data pemeriksaan sebagai masukan dalam proses prediksi. Sistem menyediakan *input* data secara manual maupun melalui impor file CSV, serta fitur pencarian, detail, edit, dan hapus data pemeriksaan.



Gambar 8. Halaman Admin Riwayat Prediksi

Halaman riwayat prediksi pada Gambar 8 menampilkan hasil deteksi dini yang meliputi nama pasien, label prediksi, nilai probabilitas atau confidence, tingkat keyakinan, *prediction set*, waktu prediksi, dan aksi untuk melihat detail hasil. Halaman ini mendukung proses pemantauan hasil prediksi oleh admin serta akses hasil deteksi dini oleh petugas. Dengan demikian, sistem tidak hanya menyediakan fungsi prediksi, tetapi juga mendukung penyimpanan dan penelusuran riwayat hasil deteksi.

Secara keseluruhan, implementasi antarmuka menunjukkan bahwa sistem telah merealisasikan kebutuhan fungsional utama, yaitu pengelolaan data pasien, pengelolaan data pemeriksaan, proses deteksi dini, penyajian hasil prediksi, monitoring data, dan pencetakan laporan. Perbedaan tampilan antara admin dan petugas juga menunjukkan bahwa sistem telah menerapkan pembatasan akses sesuai peran pengguna.

3.2 Implementasi Model Prediksi

Model prediksi pada sistem ini diimplementasikan untuk memproses data pemeriksaan dan menghasilkan klasifikasi penyakit ginjal kronis secara otomatis. Data masukan yang digunakan berupa data klinis dan faktor risiko, sedangkan keluaran sistem berupa label klasifikasi CKD atau non-CKD, probabilitas prediksi, tingkat keyakinan, dan *prediction set*. Probabilitas kelas CKD yang dihasilkan model TabNet dibandingkan dengan *threshold* sebesar 0,75. Jika probabilitas CKD $\geq 0,75$, maka data diklasifikasikan sebagai CKD, sedangkan jika probabilitas CKD $< 0,75$, maka data diklasifikasikan sebagai non-CKD. Selain menghasilkan label klasifikasi, keluaran model juga diproses menggunakan CCP. CCP digunakan untuk memberikan informasi tambahan berupa tingkat keyakinan prediksi dan *prediction set*. Dengan demikian, sistem tidak hanya menyajikan hasil klasifikasi, tetapi juga memberikan informasi apakah hasil prediksi bersifat meyakinkan atau masih memerlukan verifikasi lebih lanjut.

Sebelum hasil pengujian dirangkum dalam confusion matrix, terlebih dahulu disajikan sampel data uji dan hasil prediksi sistem. Sampel tersebut digunakan untuk menunjukkan proses pembentukan hasil klasifikasi, mulai dari data *input*, label acuan, probabilitas CKD, label prediksi, informasi keyakinan prediksi, hingga kategori hasil prediksi.

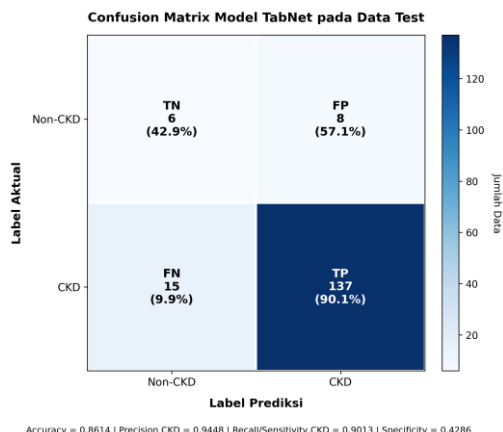
Gambar 9. Sampel Data Uji dan Hasil Prediksi Sistem

No	Age	SystolicBP	SerumCreatinine	BUNLevels	GFR	ProteinInUrine	ACR	Label Acuan	Prob. CKD	Label Prediksi	Confidence Score	Prediction Set	Status Keyakinan	Kategori
1	26	164	1,38	26,72	119,59	4,23	11,86	CKD	0,9937	CKD	0,9937	['Non-CKD', 'CKD']	Perlu Verifikasi	TP
2	81	119	0,8	9,17	96,07	4,42	230,4	Non-CKD	0,1759	Non-CKD	0,8241	['Non-CKD']	Sedang	TN
3	69	94	3,43	26,71	112,51	3,06	115,2	Non-CKD	0,9985	CKD	0,9985	['CKD']	Tinggi	FP
4	51	151	3,66	14,78	79,78	2,58	173,8	CKD	0,6951	Non-CKD	0,3049	['Non-CKD']	Sedang	FN

Gambar 9 menampilkan cuplikan sampel data uji dan hasil prediksi sistem. Cuplikan tersebut hanya memuat beberapa fitur klinis utama untuk menjaga keterbacaan, sedangkan proses prediksi sistem tetap menggunakan seluruh 23 fitur input yang telah dijelaskan pada bagian metodologi.

Kolom Prob. CKD menunjukkan probabilitas kelas CKD yang dihasilkan oleh model TabNet dan digunakan untuk menentukan label prediksi berdasarkan *threshold* sebesar 0,75. Jika Prob. CKD $\geq 0,75$, maka sistem menghasilkan prediksi CKD, sedangkan jika Prob. CKD $< 0,75$, maka sistem menghasilkan prediksi non-CKD. *Confidence score* merepresentasikan

probabilitas model terhadap label akhir yang dipilih sistem, yaitu probabilitas CKD apabila label akhir adalah CKD dan probabilitas non-CKD apabila label akhir adalah non-CKD. Sementara itu, *prediction set* merupakan keluaran CCP yang dibentuk melalui proses kalibrasi untuk menunjukkan cakupan kelas prediksi. Dengan demikian, suatu data dapat memiliki *confidence score* yang tinggi, tetapi tetap memerlukan verifikasi apabila *prediction set* mencakup lebih dari satu kelas.



Gambar 10. Confusion Matrix

Confusion matrix pada Gambar 10 diperoleh dari akumulasi hasil perbandingan antara label prediksi dan label acuan pada seluruh data uji. Setiap data uji dikelompokkan ke dalam kategori TP, TN, FP, atau FN sebagaimana ditunjukkan pada sampel Gambar 9. Berdasarkan hasil tersebut, diperoleh nilai True Negative (TN) sebesar 6, False Positive (FP) sebesar 8, False Negative (FN) sebesar 15, dan True Positive (TP) sebesar 137. Nilai True Positive yang tinggi menunjukkan bahwa model memiliki kemampuan yang baik dalam mendeteksi kasus CKD, yang juga didukung oleh nilai *recall* yang tinggi. Namun demikian, masih terdapat False Negative sebesar 15, yang menunjukkan bahwa terdapat data berlabel CKD tetapi diprediksi sebagai non-CKD. Dalam konteks deteksi dini, kondisi ini tetap perlu diperhatikan karena dapat berdampak pada keterlambatan identifikasi kasus berisiko.

Tabel 1. Metrik Klasifikasi

No	Metrik	Nilai
1	Accuracy	0,8614
2	Balanced Accuracy	0,6649
3	Precision	0,9448
4	Recall (Sensitivity)	0,9013
5	Specificity	0,4286
6	F1-Score	0,9226
7	ROC-AUC	0,7768

Hasil evaluasi kinerja model prediksi penyakit ginjal kronis ditampilkan pada Tabel 1 menggunakan beberapa metrik klasifikasi. Berdasarkan hasil pengujian, model memperoleh nilai accuracy sebesar 0,8614, yang menunjukkan bahwa sebagian besar data uji berhasil diklasifikasikan dengan benar. Nilai precision sebesar 0,9448 dan recall sebesar 0,9013 menunjukkan bahwa model memiliki kemampuan yang baik dalam memprediksi dan mendeteksi data berlabel CKD. Nilai F1-score sebesar 0,9226 juga menunjukkan keseimbangan yang baik antara *precision* dan *recall*. Namun demikian, nilai specificity sebesar 0,4286 menunjukkan bahwa kemampuan model dalam mengenali kelas non-CKD masih terbatas. Kondisi ini menunjukkan bahwa model lebih optimal dalam mengenali kelas CKD dibandingkan non-CKD. Nilai *balanced accuracy* sebesar 0,6649 dan ROC-AUC sebesar 0,7768 menunjukkan bahwa model memiliki kemampuan klasifikasi yang cukup baik secara keseluruhan, meskipun performa antar kelas belum sepenuhnya seimbang.

3.3 Pengujian Sistem

Pengujian sistem dilakukan untuk memastikan bahwa seluruh fungsi utama sistem berjalan sesuai dengan kebutuhan yang telah ditentukan. Pengujian dilakukan menggunakan metode *black box testing* dengan menguji setiap fitur utama berdasarkan skenario penggunaan sistem.

Gambar 11. Hasil Pengujian Fungsional Sistem

No	Fitur yang Diuji	Skenario Pengujian	Hasil yang Diharapkan	Hasil	Status
1	Login	Pengguna memasukkan username dan password	Sistem menampilkan dashboard	Sesuai	Berhasil
2	Data Pasien	Menambah, mengedit, dan menghapus data	Data tersimpan dan ditampilkan dengan benar	Sesuai	Berhasil
3	Data Pemeriksaan	Input data manual dan impor CSV	Data pemeriksaan berhasil disimpan	Sesuai	Berhasil
4	Proses Prediksi	Menginput data dan menjalankan prediksi	Sistem menampilkan hasil prediksi	Sesuai	Berhasil
5	Riwayat Prediksi	Melihat data hasil prediksi	Data prediksi tampil sesuai database	Sesuai	Berhasil
6	Monitoring Data	Melakukan pencarian dan filter data	Data tampil sesuai parameter filter	Sesuai	Berhasil
7	Cetak Laporan	Mengunduh laporan dalam format PDF	File laporan berhasil diunduh	Sesuai	Berhasil

Berdasarkan hasil pengujian pada Gambar 11, seluruh fitur utama sistem dapat berjalan dengan baik sesuai dengan skenario yang telah ditentukan. Tidak ditemukan kesalahan fungsional pada proses pengelolaan data, prediksi, maupun monitoring sistem. Hasil ini menunjukkan bahwa sistem yang dikembangkan telah memenuhi kebutuhan pengguna dan dapat digunakan untuk mendukung proses deteksi dini penyakit ginjal kronis secara terintegrasi.

3.4 Pembahasan

Hasil pengujian menunjukkan bahwa sistem informasi deteksi dini penyakit ginjal kronis yang dikembangkan mampu mengintegrasikan pengelolaan data, proses prediksi, penyajian hasil klasifikasi, serta informasi tingkat keyakinan prediksi dalam satu aplikasi berbasis *web*. Dari sisi performa model, nilai *accuracy* sebesar 0,8614 menunjukkan bahwa sebagian besar data uji berhasil diklasifikasikan dengan benar. Nilai *precision* sebesar 0,9448 dan *recall* sebesar 0,9013 menunjukkan bahwa model memiliki kemampuan yang baik dalam menghasilkan prediksi CKD dan mendeteksi sebagian besar data berlabel CKD. Nilai *F1-score* sebesar 0,9226 juga menunjukkan keseimbangan yang baik antara *precision* dan *recall*.

Temuan ini sejalan dengan penelitian terdahulu yang menunjukkan bahwa kecerdasan buatan dan *machine learning* memiliki potensi dalam mendukung prediksi penyakit ginjal kronis. Beberapa penelitian sebelumnya menekankan bahwa model AI dapat digunakan untuk memprediksi prognosis, progresi, maupun risiko penyakit ginjal kronis melalui evaluasi performa seperti akurasi, sensitivitas, spesifisitas, dan AUC [7], [8], [9]. Hasil penelitian ini memperkuat temuan tersebut karena model prediksi yang diintegrasikan ke dalam sistem mampu menghasilkan performa klasifikasi yang cukup baik, khususnya pada kelas CKD.

Dari sisi sistem informasi, hasil penelitian ini juga relevan dengan pengembangan sistem digital dan berbasis *web* untuk mendukung pengelolaan penyakit ginjal kronis. Penelitian terdahulu menunjukkan bahwa sistem berbasis *web* dapat digunakan untuk mendukung prediksi progresi penyakit ginjal kronis dan mortalitas pasien [5], sedangkan layanan digital terintegrasi juga telah digunakan untuk mendukung pengelolaan CKD, hipertensi, dan diabetes [6]. Selain itu, integrasi teknologi digital dinilai berpotensi mendukung skrining, pemantauan, dan pengelolaan penyakit ginjal kronis [3], [4]. Dengan demikian, penelitian ini memperkuat arah pengembangan sistem informasi kesehatan yang tidak hanya berfungsi untuk pengelolaan data, tetapi juga mendukung proses prediksi dan penyajian informasi deteksi dini.

Penggunaan TabNet dalam penelitian ini relevan karena data yang digunakan berbentuk tabular dan terdiri dari atribut klinis serta faktor risiko. TabNet dirancang untuk memproses data tabular melalui mekanisme *sequential attention*, sehingga model dapat memilih fitur penting secara adaptif pada proses pembelajaran [10]. Dalam sistem yang dikembangkan, TabNet digunakan sebagai komponen prediksi untuk menghasilkan probabilitas CKD atau non-CKD. Probabilitas tersebut kemudian digunakan untuk menentukan label klasifikasi berdasarkan *threshold* sebesar 0,75. Namun, nilai *specificity* sebesar 0,4286

menunjukkan bahwa kemampuan model dalam mengenali kelas non-CKD masih terbatas. Kondisi ini kemungkinan dipengaruhi oleh distribusi kelas yang tidak seimbang, sehingga model cenderung lebih optimal dalam mengenali kelas CKD dibandingkan non-CKD.

Penerapan CCP menjadi kontribusi penting dalam penelitian ini karena sistem tidak hanya menghasilkan label klasifikasi, tetapi juga menyajikan informasi tingkat keyakinan prediksi dan *prediction set*. Hal ini sejalan dengan literatur *medical AI* yang menekankan pentingnya ketidakpastian prediksi dalam meningkatkan keandalan penggunaan model kecerdasan buatan di bidang kesehatan [11], [12]. *Conformal prediction* juga relevan dalam konteks prediksi klinis karena dapat melengkapi keluaran model dengan informasi kepercayaan yang lebih informatif [13]. Dengan adanya CCP, sistem dapat membantu pengguna membedakan hasil prediksi yang relatif meyakinkan dan hasil yang masih memerlukan verifikasi lebih lanjut.

Kontribusi utama penelitian ini terhadap bidang Sistem Informasi terletak pada pengembangan sistem informasi kesehatan yang mengintegrasikan pengelolaan data, model prediksi, penyimpanan riwayat, monitoring, serta penyajian tingkat keyakinan prediksi dalam satu aplikasi berbasis *web*. Sistem yang dikembangkan tidak hanya berperan sebagai media pencatatan atau pelaporan data, tetapi juga sebagai sistem informasi yang mampu menghasilkan informasi prediktif untuk mendukung deteksi dini. Namun demikian, penelitian ini masih memiliki keterbatasan karena data yang digunakan diposisikan sebagai data sekunder berbentuk data dummy untuk pengembangan dan pengujian awal sistem. Oleh karena itu, hasil evaluasi belum dapat dianggap sebagai validasi klinis langsung terhadap pasien nyata. Pengujian lanjutan menggunakan data klinis yang lebih representatif diperlukan agar sistem dapat dinilai lebih kuat dalam konteks penggunaan nyata.

4. Simpulan

Penelitian ini berhasil mengembangkan sistem informasi deteksi dini penyakit ginjal kronis berbasis *web* yang terintegrasi dengan model prediksi dan mekanisme pengukuran tingkat keyakinan. Sistem yang dibangun mampu mendukung pengelolaan data, proses prediksi, penyimpanan riwayat, monitoring, dan penyajian hasil deteksi dini secara terstruktur. Penerapan CCP memungkinkan sistem menyajikan informasi tambahan berupa tingkat keyakinan prediksi dan *prediction set*. Dengan demikian, sistem ini dapat diposisikan sebagai prototipe alat bantu deteksi dini penyakit ginjal kronis pada lingkungan pengujian awal. Pengembangan selanjutnya dapat difokuskan pada pengujian menggunakan data klinis yang lebih representatif serta peningkatan kemampuan model dalam mengenali kelas non-CKD.

Daftar Referensi

- [1] M. Jadoul, M. Aoun, and M. Masimango Imani, "The major global burden of chronic kidney disease," *Lancet Glob. Heal.*, vol. 12, no. 3, pp. e342--e343, Mar. 2024, doi: 10.1016/S2214-109X(24)00050-0.
- [2] J. Li, M. Zhao, and Q. He, "Screening for chronic kidney disease: a systematic review of emerging evidence and perspectives," *Ren. Fail.*, vol. 47, no. 1, p. 2572353, Dec. 2025, doi: 10.1080/0886022X.2025.2572353.
- [3] R. K. Chinta *et al.*, "Point-of-care testing and integrated digital health technology for {CKD} screening in high-risk populations of India," *Kidney Int. Rep.*, vol. 10, no. 7, pp. 2128--2139, Jul. 2025, doi: 10.1016/j.ekir.2025.04.014.
- [4] T. Deng, Y. Xue, and N. Methakanjanasak, "Digital health integration in chronic kidney disease," *Clin. Chim. Acta*, vol. 582, no. 120749, p. 120749, Feb. 2026, doi: 10.1016/j.cca.2025.120749.
- [5] E. Kanda, B. I. Epureanu, T. Adachi, and N. Kashihara, "Machine-learning-based Web system for the prediction of chronic kidney disease progression and mortality," *PLOS Digit. Heal.*, vol. 2, no. 1, p. e0000188, Jan. 2023, doi: 10.1371/journal.pdig.0000188.
- [6] I. J. Katz *et al.*, "{IConnect} {CKD} - virtual medical consulting: A web-based chronic kidney disease, hypertension and diabetes integrated care program," *Nephrol.*, vol. 23, no. 7, pp. 646--652, Jul. 2018, doi: 10.1111/nep.13070.
- [7] Q. Pan and M. Tong, "Artificial intelligence in predicting chronic kidney disease prognosis. A systematic review and meta-analysis," *Ren. Fail.*, vol. 46, no. 2, p. 2435483, Dec. 2024, doi: 10.1080/0886022X.2024.2435483.
- [8] F. Khalid *et al.*, "Predicting the progression of chronic kidney disease: A systematic review

- of artificial intelligence and machine learning approaches,” *Cureus*, vol. 16, no. 5, p. e60145, May 2024, doi: 10.7759/cureus.60145.
- [9] Y. Yoshizaki, K. Kato, K. Fujihara, H. Sone, and K. Akazawa, “Development of a machine learning tool to predict the risk of incident chronic kidney disease using health examination data,” *Front. Public Heal.*, vol. 12, p. 1495054, Nov. 2024, doi: 10.3389/fpubh.2024.1495054.
- [10] S. Ö. Arik and T. Pfister, “{TabNet}: Attentive Interpretable Tabular Learning,” *Proc. Conf. AAAI Artif. Intell.*, vol. 35, no. 8, pp. 6679–6687, May 2021, doi: 10.1609/aaai.v35i8.16826.
- [11] A. Campagner, E. M. Biganzoli, C. Balsano, C. Cereda, and F. Cabitza, “Modeling unknowns: A vision for uncertainty-aware machine learning in healthcare,” *Int. J. Med. Inform.*, vol. 203, no. 106014, p. 106014, Nov. 2025, doi: 10.1016/j.ijmedinf.2025.106014.
- [12] T. J. Loftus *et al.*, “Uncertainty-aware deep learning in healthcare: A scoping review,” *PLOS Digit. Heal.*, vol. 1, no. 8, p. e0000085, Aug. 2022, doi: 10.1371/journal.pdig.0000085.
- [13] J. Vazquez and J. C. Facelli, “Conformal prediction in clinical medical sciences,” *J. Heal. Inform. Res.*, vol. 6, no. 3, pp. 241–252, Sep. 2022, doi: 10.1007/s41666-021-00113-8.
- [14] A. Levin *et al.*, “Executive summary of the {KDIGO} 2024 Clinical Practice Guideline for the Evaluation and Management of Chronic Kidney Disease: known knowns and known unknowns,” *Kidney Int.*, vol. 105, no. 4, pp. 684–701, Apr. 2024, doi: 10.1016/j.kint.2023.10.016.
- [15] F. Safdar and A. Aslam, “Chronic kidney disease in the primary care setting: A narrative review,” *J. Gen. Fam. Med.*, vol. 26, no. 5, pp. 385–393, Sep. 2025, doi: 10.1002/jgf2.70054.
- [16] E. S. Koh and S. Chung, “Recent update on acute kidney injury-to-chronic kidney disease transition,” *Yonsei Med. J.*, vol. 65, no. 5, pp. 247–256, May 2024, doi: 10.3349/ymj.2023.0306.
- [17] H. Hamdan, T. Y. Kim, L. C. Plantinga, H. Seligman, D. C. Crews, and D. S. Tuot, “Diet quality, food insecurity, and chronic kidney disease: Insights from the {US} National Health and Nutrition Examination Survey,” *J. Ren. Nutr.*, vol. 36, no. 2, pp. 164–171, Mar. 2026, doi: 10.1053/j.jrn.2025.10.004.