

# Model Pendeteksi Resiko Bayi Jatuh Saat Tidur Berbasis Convolutional Neural Network

## *A Fall Risk Detection Model for Infants While Sleeping Based on Convolutional Neural Networks*

<sup>1</sup>Acep Hendra\*, <sup>2</sup>Handoko Supeno

<sup>1</sup>Program Studi Sistem Informasi, Fakultas Teknologi dan Informatika, Universitas Informatika dan Bisnis Indonesia

<sup>2</sup>Program Studi Teknik Informatika, Fakultas Teknik, Universitas Pasundan

<sup>1</sup>Jl. Soekarno Hatta, Kota Bandung, Indonesia

<sup>2</sup>Jl. Setiabudhi, Kota Bandung, Indonesia

\*e-mail: [acephendra@unibi.ac.id](mailto:acephendra@unibi.ac.id), [handoko@unpas.ac.id](mailto:handoko@unpas.ac.id)

(received: 26 September 2024, revised: 7 October 2024, accepted: 25 October 2024)

### Abstrak

Jatuh dari tempat tidur adalah masalah umum pada bayi, yang sering menyebabkan cedera serius seperti trauma kepala, patah tulang, dan bahkan kerusakan neurologis jangka panjang. Menurut data dari Organisasi Kesehatan Dunia (WHO), jatuh merupakan penyebab utama cedera tidak disengaja pada anak-anak, terutama bayi. Untuk mencegah kejadian ini, diperlukan sistem deteksi dini yang efektif. Pendekatan tradisional, seperti sensor gerak dan kamera pengawas, telah digunakan untuk memantau pergerakan bayi dan mendeteksi risiko jatuh. Namun, sistem berbasis sensor memiliki keterbatasan dalam hal akurasi dan cakupan area. Sebagai alternatif, teknik visi komputer telah berkembang pesat dalam beberapa tahun terakhir, dengan Convolutional Neural Networks (CNN) terbukti sangat efektif dalam mengenali pola visual, termasuk deteksi gerakan dan postur manusia. Dalam studi ini, kami mengusulkan model berbasis CNN untuk mendeteksi risiko bayi jatuh dari tempat tidur saat tidur. Arsitektur CNN dirancang untuk secara akurat mengenali pergerakan yang menunjukkan risiko jatuh, seperti mendekati tepi tempat tidur atau perubahan posisi yang tiba-tiba. Kontribusi kami meliputi (1) desain arsitektur CNN yang mendukung pelatihan yang efektif dan efisien untuk deteksi risiko jatuh, dan (2) pembuatan dataset untuk mengklasifikasikan bayi sebagai aman atau berisiko jatuh. Hasil eksperimen menunjukkan bahwa sistem yang kami usulkan mencapai akurasi tinggi dalam mendeteksi potensi risiko jatuh, sehingga menyediakan solusi yang dapat diandalkan untuk pemantauan keselamatan bayi.

**Kata kunci:** convolutional neural network (CNN), visi komputer, dan deteksi risiko jatuh

### Abstract

*Falling from a bed is a common problem among infants, often leading to serious injuries such as head trauma, fractures, and even long-term neurological damage. According to data from the World Health Organization (WHO), falls are a leading cause of unintentional injuries among children, especially infants. To prevent these incidents, an effective early detection system is needed. Traditional approaches, such as motion sensors and surveillance cameras, have been employed to monitor infant movements and detect fall risks. However, sensor-based systems face limitations in terms of accuracy and coverage area. As an alternative, computer vision techniques have shown rapid advancements in recent years, with Convolutional Neural Networks (CNNs) proving to be highly effective in recognizing visual patterns, including human motion and posture detection. In this study, we propose a CNN-based model to detect the risk of infants falling from a bed while sleeping. The CNN architecture is designed to accurately recognize movements indicative of fall risks, such as approaching the edge of the bed or sudden changes in posture. Our contributions include (1) the design of a CNN architecture that supports effective and efficient training for fall risk detection, and (2) the creation of a dataset to classify infants as either safe or at risk of falling. Experimental results*

<http://sistemasi.ftik.unisi.ac.id>

*demonstrate that our proposed system achieves high accuracy in detecting potential fall risks, providing a reliable solution for infant safety monitoring.*

*Keywords: Convolutional Neural Network (CNN), Computer Vision, dan Fall Risk Detection*

## 1. Pendahuluan

Jatuh merupakan masalah kesehatan utama di seluruh dunia, terutama dalam dunia kesehatan karena pasien jatuh merupakan masalah terparah yang terus terjadi. Kebanyakan pasien yang jatuh dari tempat tidur tidak disaksikan. Hal ini diperparah dengan berbagai masalah kesehatan yang bisa diakibatkan oleh jatuh. Kecelakaan jatuh dari tempat tidur adalah salah satu masalah yang sering terjadi pada bayi, yang dapat menyebabkan cedera serius seperti trauma kepala, patah tulang, hingga gangguan perkembangan saraf (Morrongiello, 2017)[1]. Menurut data dari WHO, jatuh adalah penyebab utama cedera tak sengaja di kalangan anak-anak, terutama bayi. Oleh karena itu, diperlukan sistem pendeteksi dini yang efektif untuk mencegah bayi jatuh dari tempat tidur.

Berbagai pendekatan telah diusulkan untuk memantau pergerakan bayi dan mendeteksi risiko jatuh, mulai dari sensor gerak hingga kamera pengawas. Namun, sistem berbasis sensor memiliki keterbatasan dalam hal akurasi dan cakupan area (Liu, 2023)[2]. Sebagai alternatif, pendekatan berbasis visi komputer menggunakan teknologi pengolahan citra telah berkembang pesat dalam beberapa tahun terakhir. Convolutional Neural Network (CNN) telah terbukti menjadi salah satu metode yang efektif dalam pengenalan pola visual, terutama dalam mendeteksi gerakan dan postur manusia seperti yang diteliti oleh (LeCun, 2015) [3] dan (Nooruddin,2022)[4].

CNN merupakan jenis arsitektur jaringan saraf tiruan yang mampu mengekstraksi fitur visual secara hierarkis dari gambar. Dalam konteks deteksi risiko jatuh, CNN dapat dilatih untuk mengenali pola pergerakan yang mencerminkan potensi risiko jatuh, seperti pergerakan mendekati tepi ranjang atau perubahan posisi yang tiba-tiba. Metode ini memiliki keunggulan dalam hal akurasi tinggi dibandingkan dengan pendekatan konvensional lainnya

Oleh karena itu diperlukan sebuah arsitektur berbasis jaringan syaraf konvolusi yang mampu menghasilkan pelatihan pembelajaran mesin dalam yang efektif dan efisien untuk mendeteksi resiko jatuh pada bayi. Kontribusi pada penelitian ini antara lain bertujuan untuk menghasilkan desain CNN yang dapat mendukung pelatihan untuk mendeteksi resiko jatuh bayi serta dataset untuk klasifikasi bayi aman dan beresiko jatuh dari ranjang. Sehingga dapat berkontribusi untuk mengurangi resiko bayi/balita jatuh dari ranjang secara preventif berbantuan teknologi *computer vision*.

## 2. Penelitian Terdahulu

Beberapa penelitian terkait deteksi jatuh menggunakan berbagai pendekatan telah dilakukan sebelumnya. Penelitian-penelitian ini memiliki fokus pada deteksi jatuh setelah kejadian terjadi, tanpa adanya pencegahan dini atau tindakan preventif yang efektif, terutama pada bayi saat tidur. Berikut adalah beberapa penelitian yang relevan:

Pada penelitian yang dilakukan Bhaskoro[5] berjudul "*Sistem Identifikasi Manusia Bergerak Jatuh Berdasarkan Ekstraksi Suara dan Citra*" yang memanfaatkan ekstraksi suara dan citra untuk mendeteksi jatuh pada manusia. Pendekatan ini menggabungkan dua modalitas suara dan citra dalam mengidentifikasi

pergerakan yang berisiko jatuh. Namun, penelitian ini lebih terfokus pada identifikasi jatuh pada manusia dewasa dan tidak memberikan solusi preventif pada kasus bayi yang rentan jatuh saat tidur.

Pada penelitian yang dilakukan oleh Tan[6] dalam makalahnya "*Enhancing Child Safety: Computer Vision-Based Accident Detection for Infants and Toddlers*" mengusulkan pendekatan berbasis visi komputer untuk mendeteksi kecelakaan pada bayi dan balita. Fokus utama dari penelitian ini adalah pada deteksi pasca-kecelakaan, di mana sistem mendeteksi ketika insiden sudah terjadi, tanpa adanya mekanisme pencegahan yang aktif untuk mencegah jatuh dari tempat tidur. Sementara pendekatan berbasis citra yang digunakan relevan, penelitian ini kurang fokus pada pencegahan dini.

Pada penelitian yang dilakukan oleh Khan[7] berjudul "*Fall prevention from scaffolding using computer vision and IoT-based monitoring*" meneliti pencegahan jatuh pada pekerja konstruksi menggunakan visi komputer dan pemantauan berbasis IoT. Meskipun penelitian ini menawarkan solusi preventif untuk mencegah jatuh, target utamanya adalah orang dewasa di tempat kerja, bukan bayi. Pendekatan ini menggunakan deteksi pergerakan berbasis visi yang bisa menjadi dasar bagi aplikasi lain, tetapi belum dioptimalkan untuk skenario bayi yang rentan jatuh saat tidur.

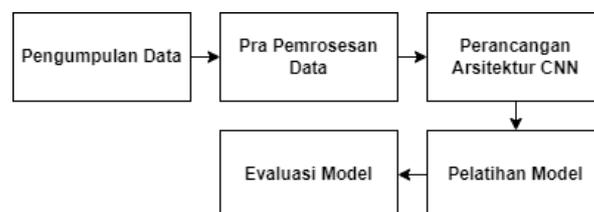
Pada penelitian yang dilakukan oleh Oumaima[8] dalam ulasannya "*Vision-based fall detection and prevention for the elderly people: A review & ongoing research*" berfokus pada deteksi jatuh pada lansia. Penelitian ini mengevaluasi berbagai pendekatan berbasis visi untuk mendeteksi dan mencegah jatuh pada kelompok lansia. Sama seperti penelitian sebelumnya, pendekatan ini cenderung lebih reaktif daripada preventif, dengan fokus utama pada lansia, dan tidak menangani kebutuhan spesifik bayi yang berada dalam posisi tidur.

Pada penelitian yang dilakukan oleh Sree[9] dalam makalah "*A computer vision based fall detection technique for home surveillance*" mengembangkan teknik deteksi jatuh berbasis visi komputer untuk pemantauan di rumah. Penelitian ini menawarkan solusi untuk mendeteksi jatuh di lingkungan rumah tangga, namun tidak spesifik menangani kasus bayi yang jatuh dari tempat tidur, dan lebih fokus pada deteksi setelah kejadian.

Penelitian-penelitian di atas lebih menekankan pada deteksi jatuh setelah kejadian atau pada populasi dewasa, baik dalam skenario kerja maupun lansia padahal resiko jatuh tidak bisa diabaikan (Irdawati) [10] sehingga sistem yang mendeteksi kejadian setelah jatuh menjadi tidak relevan menurut kami untuk keselamatan bayi. Penelitian kami memiliki keunggulan yang lebih bersifat preventif, khususnya dalam konteks bayi yang rentan jatuh saat tidur. Pendekatan berbasis *Convolutional Neural Network* (CNN) yang diusulkan dalam penelitian ini berfokus pada deteksi pergerakan yang berisiko secara dini, seperti mendekati tepi ranjang atau perubahan posisi yang mendadak. Dengan demikian, sistem ini tidak hanya mendeteksi setelah bayi jatuh, tetapi juga mencegah insiden jatuh dengan memberikan peringatan sebelum kejadian terjadi. Solusi ini diharapkan dapat memberikan kontribusi signifikan dalam meningkatkan keselamatan bayi saat tidur.

### 3. Metode Penelitian

Penelitian ini bertujuan untuk mengembangkan model pendeteksi risiko jatuh pada bayi dari ranjang berbasis *Convolutional Neural Network* (CNN) (Li) [11]. Untuk mencapai tujuan tersebut, metode penelitian dibagi ke dalam beberapa tahapan utama, yaitu pengumpulan data, preprocessing data, perancangan model CNN, pelatihan model, dan evaluasi model yang lazim digunakan pada proyek-proyek di visi komputer. Setiap tahapan dijelaskan secara rinci sebagaimana yang ditampilkan pada Gambar 1 berikut.



**Gambar 1. Alur penelitian model pendeteksi resiko jatuh**

#### 2.1. Pengumpulan Data

Tahap pertama dari penelitian ini adalah pengumpulan data berupa citra bayi yang sedang berada di ranjang. Dataset yang digunakan dalam penelitian ini diperoleh dari sumber daring dan rekaman CCTV (Choi)[12] yang relevan dengan penelitian ini. Gambar yang didapatkan kemudian dilakukan beberapa transformasi untuk memperkaya dataset yang akan digunakan.

Data tersebut diklasifikasikan ke dalam dua kategori utama, yaitu:

**Citra aman:** Bayi berada dalam posisi aman di tengah ranjang. Gambaran dataset yang digunakan

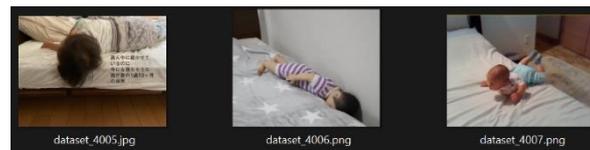
<http://sistemasi.ftik.unisi.ac.id>

untuk klasifikasi kondisi aman ditunjukkan pada Gambar 2 di bawah ini.



**Gambar 2. Contoh Beberapa Dataset Yang Digunakan Untuk Kondisi Aman Bayi**

**Citra risiko jatuh:** Bayi berada di tepi ranjang atau dalam posisi yang berpotensi menyebabkan jatuh. Gambaran dataset yang digunakan untuk klasifikasi kondisi aman ditunjukkan pada Gambar 3 di bawah ini.



**Gambar 3. Contoh Beberapa Dataset Yang Digunakan Untuk Kondisi Beresiko Jatuh Pada Bayi**

Sebanyak 1.270 citra digunakan dalam penelitian ini, dengan 70% data digunakan untuk pelatihan, 20% untuk validasi, dan 10% untuk pengujian model.

## 2.2. Pra pemrosesan Data

Data yang diperoleh melalui tahap pengumpulan selanjutnya diproses agar dapat digunakan untuk melatih model CNN. Langkah-langkah preprocessing yang dilakukan adalah sebagai berikut:

**Resize:** Semua citra diubah ukurannya menjadi 256x256 piksel untuk menyesuaikan dengan input layer CNN.

**Normalisasi:** Nilai piksel citra dinormalisasi ke rentang [0,1] dengan membagi setiap nilai piksel dengan 255.

**Augmentasi:** Untuk meningkatkan variasi data, dilakukan augmentasi citra seperti rotasi, flipping horizontal, zoom, dan translasi. Teknik augmentasi ini bertujuan untuk mengatasi overfitting dan meningkatkan performa model dalam mendeteksi berbagai situasi.

**Penentuan Direktori Dataset:** Pertama, kita menentukan lokasi direktori yang berisi dataset gambar. Direktori ini berisi subdirektori yang merupakan kelas gambar yang berbeda.

**Pemeriksaan Ekstensi Gambar:** Seluruh gambar dalam direktori diperiksa untuk memastikan bahwa ekstensi file mereka sesuai dengan format yang diizinkan seperti 'jpeg', 'jpg', 'bmp', dan 'png'. Gambar yang tidak sesuai dengan format yang diizinkan akan dihapus.

**Membuat Dataset dari Direktori:** Dataset gambar dibuat dari direktori yang sudah dibersihkan menggunakan utilitas TensorFlow. Langkah ini memungkinkan dataset untuk diakses dan digunakan dalam pelatihan model.

**Pembagian Dataset:** Dataset dibagi menjadi tiga bagian: training set (70%), validation set (20%), dan test set (10%). Pembagian ini bertujuan untuk melatih model dengan data yang cukup, memvalidasi performa model, dan menguji generalisasi model pada data yang tidak terlihat sebelumnya.

## 2.3. Perancangan Arsitektur CNN

Arsitektur CNN yang digunakan dalam penelitian ini dirancang untuk melakukan tugas klasifikasi biner yang telah terbukti berhasil untuk mengklasifikasikan beragam kasus dalam beberapa riset

seperti (Lu) [13], (Ayadi)[14], dan (Beni-suef) [15]. Arsitektur yang digunakan terdiri dari beberapa lapisan, yaitu:

**Input Layer:** Menerima citra berukuran 256x256 piksel dengan 3 saluran (RGB).

**Convolutional Layers:** Terdiri dari 3 lapisan konvolusi berturut-turut yaitu lapisan konvolusi pertama yang menggunakan 16 filter dengan ukuran 3x3 dan stride 1. Dilengkapi dengan fungsi aktivasi ReLU (Rectified Linear Unit). Lapisan konvolusi kedua: Menggunakan 32 filter dengan ukuran 3x3 dan stride 1. Dilengkapi dengan fungsi aktivasi ReLU. Lapisan konvolusi ketiga: Menggunakan 64 filter dengan ukuran 3x3 dan stride 1. Dilengkapi dengan fungsi aktivasi ReLU.

**Pooling Layers:** Max pooling dengan ukuran filter 2x2 digunakan setelah setiap lapisan konvolusi untuk mengurangi dimensi spasial.

**Fully Connected Layers:** Setelah lapisan konvolusi terakhir, digunakan satu lapisan fully connected dengan 256 neuron dan fungsi aktivasi ReLU.

**Output Layer:** Lapisan keluaran terdiri dari 1 neuron dengan fungsi aktivasi sigmoid untuk memprediksi probabilitas klasifikasi.

Arsitektur ini dirancang untuk menangani tugas klasifikasi biner gambar berukuran 256x256 piksel. Setiap lapisan konvolusi diikuti oleh lapisan pooling untuk mengurangi dimensi spasial dari fitur maps, yang membantu dalam mengurangi overfitting dan jumlah parameter yang harus dipelajari. Lapisan dense pada akhir model menggabungkan fitur yang diekstraksi dan memetakan mereka ke dalam kelas output melalui lapisan output dengan fungsi aktivasi sigmoid.

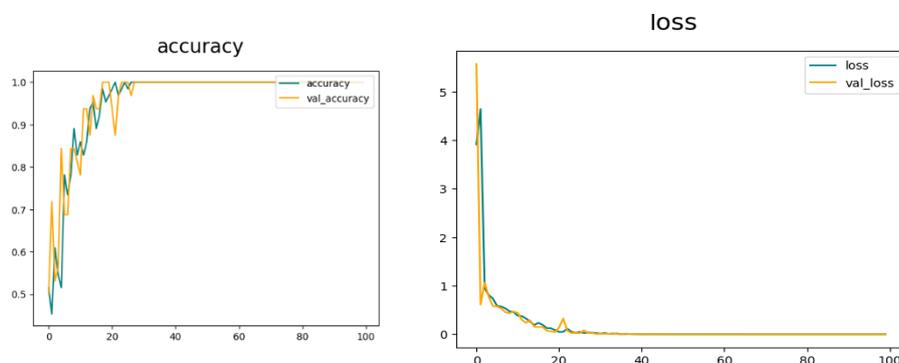
#### 2.4. Pelatihan Model

Model ini dikompilasi menggunakan optimasi 'adam' dan fungsi loss BinaryCrossentropy, yang cocok untuk tugas klasifikasi biner. Metode evaluasi yang digunakan adalah accuracy. Model ini dikompilasi menggunakan optimasi 'adam' dan fungsi loss BinaryCrossentropy, yang cocok untuk tugas klasifikasi biner. Metode evaluasi yang digunakan adalah accuracy.

Dengan arsitektur ini, model diharapkan mampu mempelajari fitur-fitur penting dari citra yang digunakan untuk mendeteksi risiko jatuh bayi dengan akurasi tinggi. Setiap lapisan konvolusi membantu dalam menangkap fitur spasial yang relevan, sementara lapisan pooling membantu dalam mengurangi dimensi dan menghindari overfitting. Lapisan fully connected akhirnya menggabungkan semua fitur yang dipelajari untuk memberikan prediksi akhir.

### 3. Hasil dan Pembahasan

Setelah model Convolutional Neural Network (CNN) yang dirancang selesai dilatih, dilakukan pengujian menggunakan dataset uji untuk mengevaluasi kinerjanya dalam mendeteksi risiko jatuh bayi dari ranjang. Hasil evaluasi model dari aspek loss dan accuracy menghasilkan performa yang baik. Penggambaran loss dan accuracy dapat dilihat pada Gambar 4 di bawah ini:



Gambar 4. Grafik accuracy (kiri) dan Grafik loss (kanan)

Grafik loss menunjukkan nilai loss selama pelatihan dan validasi untuk 100 epoch. Dari grafik tersebut, beberapa poin penting dapat disimpulkan:

1. **Penurunan Loss yang Cepat:** Pada awal pelatihan, baik loss pelatihan (loss) maupun loss validasi (val\_loss) menurun dengan sangat cepat. Ini menunjukkan bahwa model belajar dengan cepat untuk meminimalkan kesalahan pada data pelatihan dan validasi.
2. **Konsistensi Setelah Epoch ke-3:** Setelah beberapa epoch awal, nilai loss untuk pelatihan dan validasi menjadi lebih stabil dan konsisten. Ini menandakan bahwa model telah mulai mencapai titik konvergensi di mana penurunan loss tidak lagi signifikan.
3. **Overfitting:** Grafik loss validasi yang cenderung mengikuti pola yang sama dengan loss pelatihan menunjukkan bahwa model tidak mengalami overfitting yang signifikan. Namun, fluktuasi kecil dalam loss validasi dapat mengindikasikan bahwa model masih belajar dan menyesuaikan parameter untuk mencapai performa optimal.

Grafik akurasi menunjukkan nilai akurasi selama pelatihan dan validasi untuk 20 epoch. Dari grafik tersebut, beberapa poin penting dapat disimpulkan:

1. **Peningkatan Akurasi yang Cepat:** Pada awal pelatihan, akurasi pelatihan (accuracy) dan akurasi validasi (val\_accuracy) meningkat dengan cepat. Ini menunjukkan bahwa model cepat dalam mengenali pola yang ada dalam data pelatihan dan validasi.
2. **Fluktuasi Akurasi:** Akurasi validasi menunjukkan beberapa fluktuasi yang lebih besar dibandingkan dengan akurasi pelatihan. Ini menunjukkan bahwa model masih mengalami beberapa variasi dalam kinerjanya pada data yang belum pernah dilihat sebelumnya.
3. **Akurasi yang Mendekati 90%:** Pada akhir pelatihan, baik akurasi pelatihan maupun akurasi validasi mendekati 90%. Ini menandakan bahwa model memiliki performa yang cukup baik dalam tugas klasifikasi risiko jatuh bayi. Hasil pengujian untuk gambar test untuk kasus bayi dalam kondisi aman ditunjukkan pada Gambar 5 di bawah ini:



**Gambar 5. (Kiri) Pengujian Gambar Bayi/Balita Dalam Kondisi Aman. (Kanan) Pengujian Gambar Bayi/Balita Dalam Kondisi Beresiko Jatuh**

#### 4. Kesimpulan

Computer Vision telah banyak digunakan pada solusi-solusi yang berhubungan dengan aktivitas manusia seperti pada (Pramuditha)[16]. Penelitian ini berhasil mengembangkan model pendeteksi risiko jatuh pada bayi dari ranjang berbasis Convolutional Neural Network (CNN). Model ini dilatih menggunakan dataset citra bayi yang meliputi berbagai skenario posisi aman dan risiko jatuh, dengan hasil evaluasi yang menunjukkan performa yang sangat baik. Keunggulan utama dari pendekatan berbasis CNN ini adalah kemampuannya untuk memproses citra secara langsung tanpa memerlukan feature engineering manual, serta robust terhadap berbagai variasi posisi bayi dan kondisi pencahayaan. Penggunaan teknik augmentasi data dan regularisasi seperti dropout juga terbukti membantu dalam mengurangi overfitting dan meningkatkan generalisasi model. Meskipun demikian,

terdapat beberapa keterbatasan yang perlu diperhatikan yaitu masih belum real time. Ke depan, penelitian ini dapat diperluas dengan mengimplementasikannya pada perangkat pengawasan atau di mobile phone dan mengirim notifikasi jika bayi atau balita berada dalam kondisi beresiko jatuh.

## Referensi

- [1] B. A. Morrongiello and D. C. Schwebel, "Introduction to Special Section: Pediatric Psychology and Child Unintentional Injury Prevention: Current State and Future Directions for the Field," *J. Pediatr. Psychol.*, vol. 42, no. 7, pp. 721–726, Aug. 2017, doi: 10.1093/jpepsy/jsx072.
- [2] J. Liu *et al.*, "A review of wearable sensors based fall-related recognition systems," *Eng. Appl. Artif. Intell.*, vol. 121, p. 105993, May 2023, doi: 10.1016/j.engappai.2023.105993.
- [3] Y. LeCun, Y. Bengio, and G. Hinton, "Deep learning," *Nature*, vol. 521, no. 7553, pp. 436–444, May 2015, doi: 10.1038/nature14539.
- [4] S. Nooruddin, Md. M. Islam, F. A. Sharna, H. Alhetari, and M. N. Kabir, "Sensor-based fall detection systems: a review," *J. Ambient Intell. Humaniz. Comput.*, vol. 13, no. 5, pp. 2735–2751, May 2022, doi: 10.1007/s12652-021-03248-z.
- [5] Susetyo Bagas Bhaskoro, E. A. Salsabillah, and Afaf Fadhil Rifa'i, "Sistem Identifikasi Manusia Bergerak Jatuh Berdasarkan Ekstraksi Suara dan Citra," *JTRM J. Teknol. Dan Rekayasa Manufaktur*, vol. 4, no. 2, pp. 101–116, Dec. 2022, doi: 10.48182/jtrm.v4i2.94.
- [6] J. H. Tan and C. P. Goh, "Enhancing Child Safety: Computer Vision-Based Accident Detection for Infants and Toddlers," in *2024 3rd International Conference on Digital Transformation and Applications (ICDXA)*, Kuala Lumpur, Malaysia: IEEE, Jan. 2024, pp. 1–5. doi: 10.1109/ICDXA61007.2024.10470712.
- [7] M. Khan, R. Khalid, S. Anjum, S. V.-T. Tran, and C. Park, "Fall Prevention from Scaffolding Using Computer Vision and IoT-Based Monitoring," *J. Constr. Eng. Manag.*, vol. 148, no. 7, p. 04022051, Jul. 2022, doi: 10.1061/(ASCE)CO.1943-7862.0002278.
- [8] G. Oumaima, A. A. Hamd, T. Youness, O. H. T. Rachid, and B. Omar, "Vision-based fall detection and prevention for the elderly people: A review & ongoing research," in *2021 Fifth International Conference On Intelligent Computing in Data Sciences (ICDS)*, Fez, Morocco: IEEE, Oct. 2021, pp. 1–6. doi: 10.1109/ICDS53782.2021.9626736.
- [9] K. V. Sree and G. Jeyakumar, "A Computer Vision Based Fall Detection Technique for Home Surveillance," in *Computational Vision and Bio-Inspired Computing*, vol. 1108, S. Smys, J. M. R. S. Tavares, V. E. Balas, and A. M. Iliyasu, Eds., in *Advances in Intelligent Systems and Computing*, vol. 1108. , Cham: Springer International Publishing, 2020, pp. 355–363. doi: 10.1007/978-3-030-37218-7\_41.
- [10] I. Irdawati, J. Ramadhanni, and A. R. Syaiful, "Overview of Parents' Knowledge About Accident Prevention in Toddler," *J. Ber. Ilmu Keperawatan*, vol. 16, no. 1, pp. 47–52, Feb. 2023, doi: 10.23917/bik.v16i1.1014.

- [11]Z. Li, F. Liu, W. Yang, S. Peng, and J. Zhou, “A Survey of Convolutional Neural Networks: Analysis, Applications, and Prospects,” *IEEE Trans. Neural Netw. Learn. Syst.*, vol. 33, no. 12, pp. 6999–7019, Dec. 2022, doi: 10.1109/TNNLS.2021.3084827.
- [12]S. Choi, S. Yun, and B. Ahn, “Implementation of Automated Baby Monitoring: CCBeBe,” *Sustainability*, vol. 12, no. 6, p. 2513, Mar. 2020, doi: 10.3390/su12062513.
- [13]J. Lu, L. Tan, and H. Jiang, “Review on Convolutional Neural Network (CNN) Applied to Plant Leaf Disease Classification,” *Agriculture*, vol. 11, no. 8, p. 707, Jul. 2021, doi: 10.3390/agriculture11080707.
- [14]W. Ayadi, W. Elhamzi, I. Charfi, and M. Atri, “Deep CNN for Brain Tumor Classification,” *Neural Process. Lett.*, vol. 53, no. 1, pp. 671–700, Feb. 2021, doi: 10.1007/s11063-020-10398-2.
- [15]Faculty of Computers and Artificial Intelligence, Beni-Suef University, Beni-Suef City, 62511, Egypt *et al.*, “Image Classification Based On CNN: A Survey,” *J. Cybersecurity Inf. Manag.*, p. PP. 18-50, 2021, doi: 10.54216/JCIM.060102.
- [16]A. Z. Pramuditha, S. Suroso, and M. F. Fadhli, “Face Detection Dengan Model Arsitektur VGG 19 Pada Metode Convolutional Neural Network,” *SISTEMASI*, vol. 13, no. 5, p. 1998, Sep. 2024, doi: 10.32520/stmsi.v13i5.4399.