



## Convolutional neural networks for early melanoma detection using dermoscopic images: a literature review

Martyna Karmazinaitė<sup>1</sup>, Rapolas Šalaševičius<sup>2</sup>

<sup>1</sup>Vilnius University, Faculty of Medicine, Vilnius, Lithuania

<sup>2</sup>Elektrenai hospital, Elektrenai, Lithuania

### Abstract

**Background:** artificial intelligence (AI) is reshaping dermatology, offering faster and more accurate diagnoses, particularly for conditions like melanoma. Melanoma, a deadly form of skin cancer, requires early detection for effective treatment. Dermoscopy, aided by Convolutional Neural Networks (CNN), has emerged as a promising approach for early melanoma detection. As melanoma incidence rises, AI-driven solutions offer hope for more efficient diagnoses and improved patient outcomes.

**Aim:** To analyze the potential of convolutional neural networks (CNN) for early detection of melanoma using dermatoscopy images. We aim to review how CNN can effectively analyze and classify dermoscopic images to accurately identify suspicious skin lesions.

**Methodology:** articles were searched in the PubMed and Google Scholar databases. The search used keywords and their combinations, such as melanoma, convolutional neural networks, dermoscope. Articles whose title or keywords matched the purpose of this literature review were selected for analysis.

**Results:** CNN have shown superior diagnostic accuracy compared to traditional methods. Collaborative approaches between CNN and dermatologists showing promise in improving diagnostic outcomes.

**Conclusions:** the integration of artificial intelligence into dermatology is transforming the detection and diagnosis of skin diseases like melanoma. Convolutional neural networks have shown exceptional performance in analyzing dermoscopic images and distinguishing benign from malignant lesions. With melanoma incidence on the rise, leveraging artificial intelligence becomes increasingly essential for swift and accurate diagnoses globally, ultimately enhancing outcomes for patients battling the disease.

**Keywords:** melanoma, convolutional neural networks, patterns, borders, augmentation, data preprocessing, machine learning algorithms, dermoscopy.

# Konvoliuciniai neuroniniai tinklai ankstyvam melanomos aptikimui naudojant dermatoskopinius vaizdus: literatūros apžvalga

Martyna Karmazinaitė<sup>1</sup>, Rapolas Šalaševičius<sup>2</sup>

<sup>1</sup>Vilniaus universiteto Medicinos fakultetas, Vilnius, Lietuva

<sup>2</sup>Elektrėnų ligoninė, Elektrėnai, Lietuva

## Santrauka

**Įvadas:** dirbtinis intelektas daro didelę įtaką dermatologijoje, pagerina ankstyvą odos ligų nustatymą ir diagnostiką. Melanoma, kilusi iš pigmentą gaminančių melanocitų, jei negydoma ankstyvoje stadijoje, yra metastazuoti galinti odos vėžio forma. Dermatoskopas atlieka lemiamą vaidmenį melanomos diagnozėje, pagerina vizualizaciją ir paternų aptikimą. Konvoliuciniai neuroniniai tinklai (angl. *convolutional neural networks*, *CNN*) - giliojo mokymosi technika, galinti efektyviai analizuoti dermatoskopinius vaizdus ir sukelianti revoliuciją medicininių vaizdų analizėje.

**Tikslas:** apžvelgti konvoliucinių neuronų tinklų potencialą anksti aptikti melanomą naudojant dermatoskopijos vaizdus. Siekiame apžvelgti, kaip CNN gali veiksmingai analizuoti ir klasifikuoti dermatoskopinius atvaizdus, kad tiksliai nustatytų įtartinus odos pažeidimus.

**Metodika:** straipsnių paieška vykdyta PubMed ir Google Scholar duomenų bazėse. Paieškoje buvo naudojami raktiniai žodžiai ir jų deriniai, tokie kaip melanoma, konvoliuciniai neuroniniai tinklai, dermatoskopas. Analizei buvo atrinkti straipsniai, kurių pavadinimas ar raktiniai žodžiai atitiko šios literatūros apžvalgos tikslą.

**Rezultatai:** CNN parodė geresnę diagnostikos našumą nei tradiciniai metodai. Dermatologams į praktiką įtraukus CNN modelį, stebimas potencialas pagerinti diagnostikos tikslumą, specifiškumą ir jautrumą.

**Išvados:** dirbtinio intelekto integravimas į dermatologiją keičia odos ligų, tokių kaip melanoma, aptikimą ir diagnostiką. Konvoliuciniai neuroniniai tinklai parodė išskirtinį našumą analizuodami dermatoskopinius vaizdus, atskirdami gerybinius nuo piktybinių pažeidimų. Daugėjant melanomos atvejų, dirbtinio intelekto naudojimas tampa vis svarbesnis, kad pacientams visame pasaulyje būtų suteikta greitesnė ir tikslesnė diagnozė.

**Raktažodžiai:** melanoma, konvoliuciniai neuroniniai tinklai, paternai, briaunos, augmentacija, išankstinis duomenų apdorojimas, mašininio mokymosi algoritmai, dermoskopija.

## 1. Įvadas

Šiais laikais dirbtinis intelektas dermatologijoje daro didelę įtaką, nes padeda geriau anksti nustatyti ir diagnozuoti odos ligas. Tokios šalys kaip JAV, Kinija ir Vokietija pirmąją integruodamos dirbtinį intelektą į dermatologijos praktiką: siekiant diagnozuoti melanomą kuo anksčiau, naudojamos dirbtinio intelekto valdomos sistemos dermatoskopiniams vaizdams analizuoti. Ši technologija kelia revoliuciją dermatologijos srityje, siūlydama greitesnę ir tikslesnę diagnozę pacientams visame pasaulyje. Melanoma yra odos vėžio rūšis, kuri išsivysto iš pigmentą gaminančių ląstelių, vadinamų melanocitais. Tai laikoma sunkiausia odos vėžio forma, nes ji gali išplisti į kitas kūno dalis, jei nebus aptikta ir gydoma anksti. Melanoma gali atsirasti bet kurioje kūno vietoje, tačiau dažniausiai lokalizuojasi liemens srityje vyrams, moterims – apatinių galūnių. Ji taip pat gali išsivystyti ir kitose srityse, pavyzdžiui, akyse, burnoje ir lytiniuose organuose [1]. Melanoma yra gana reta lyginant su kitomis odos vėžio rūšimis, tačiau per pastaruosius kelis dešimtmečius jos dažnis didėja. Tarptautinės vėžio tyrimų agentūros duomenimis, 2020 metais bendras melanomos atvejų skaičius buvo 324 439. Numatomas 2025 metais – 350 941, taip pat 2030 metais – 377 318, per dešimtmetį išaugant apie 15 procentų. Penkerių metų išgyvenamumas pacientams, sergantiems lokalizuota ligos forma yra 97 procentai. Tačiau pacientų, sergančių IV ligos stadija, penkerių metų išgyvenamumas siekia tik 10 procentų, todėl ankstyva melanomos diagnostika yra labai svarbi [2]. Dermoskopija yra neinvazinis in vivo diagnostikos metodas įtartiniams odos pažeidimams įvertinti pasitelkiant dermatoskopą, ir yra ypač svarbi diagnozuojant melanomą. Dermatoskopas imituoja didinamąjį lęšį su papildoma reguliuojama integruota apšvietimo sistema, tai leidžia geresnę vizualizaciją, pateną nustatymą ir didesnį

diagnostinį tikslumą [3,4]. Dermatoskopinius vaizdus galima analizuoti naudojant konvoliucinius neuroninius tinklus (angl. *convolutional neural networks, CNN*) - giliojo mokymosi algoritmo techniką, kuri sukėlė revoliuciją medicininio vaizdavimo analizės srityje. CNN medicinoje tampa vis svarbesnis metodas dėl gebėjimo analizuoti ir interpretuoti sudėtingus medicininius atvaizdus, tokius kaip rentgeno, MRT, kompiuterinės tomografijos, histopatologinius ir dermatoskopinius [5].

## 2. Metodika

Straipsnių paieška vykdyta PubMed ir Google Scholar duomenų bazėse. Paieškoje buvo naudojami raktiniai žodžiai ir jų deriniai, tokie kaip melanoma, konvoliuciniai neuroniniai tinklai, dermatoskopas. Analizei buvo atrinkti straipsniai, kurių pavadinimas ar raktiniai žodžiai atitiko šios literatūros apžvalgos tikslą.

## 3. Rezultatai

### 3.1 Dermoskopija

Terminą „dermoskopija“ 1970 m. pirmą kartą panaudojo austrų dermatologas Johanas Saphieris. Jis taikė dermoskopiją daugiausia odos kapiliarams įvertinti normaliomis ir pataloginėmis sąlygomis, o pigmentinių odos pakitimų aprašymas ir diagnostika tuo laikotarpiu nevaikino didelio vaidmens. Pirmieji darbai apie dermoskopijos taikymą melanomos diagnozei datuojami 1971 metais [6]. Pagrindinis dermoskopijos principas yra pažeidimo transiluminacija, siekiant ištirti jį dideliu padidiniu bei vizualizuoti subtilius bruožus, dažnai pasitelkiant imersinį skystį. Kad būtų galima palyginti atvaizdus ateityje, dermatoskopas gali juos įrašyti [3]. Nepaisant pastangų tobulinti melanomos diagnozę, klaidingas diagnozavimas ir neteisingas stadijavimas išlieka pripažinta dermatopatologijos problema. Vienas iš esamų melanomos nustatymo iššūkių yra tiksliai atskirti gerybinius ir piktybinius odos

pažeidimus ankstyvosiose ligos stadijose. Tai gali lemti uždelstą diagnozę ir gydymą, tuo pačiu blogesnes ligos išėitis, padidinti perteklinių biopsijų skaičių [7]. CNN mašininio mokymosi algoritmas parodė didelį potencialą nustatyti ankstyvą melanomą analizuojant odos vaizdinius duomenis [12,13,14].

### 3.2 Konvoliuciniai neuroniniai tinklai

Per pastaruosius du dešimtmečius konvoliuciniai neuroniniai tinklai (CNN) tapo neįkainojama biomedicininų atvaizdų klasifikavimo priemone ir buvo pasiūlyti kaip klinikinės diagnostikos priemonė tokiose srityse kaip radiologija, histologija, oftalmologija ir dermatologija. CNN yra gilaus mokymosi algoritmo tipas – kompiuterinės programinės įrangos forma, kuri greitai ir tiksliai supranta ir atpažįsta vaizdinius duomenis [8]. Konvoliuciniai neuroniniai tinklai yra labai tinkami atvaizdų analizės užduotims dėl jų gebėjimo automatiškai apdoroti sudėtingas atvaizdų savybes. CNN naudoja skirtingus konvoliucinius sluoksnius, kad rastų įvesties duomenų ryšius, paternus ir ypatybes, kurie nėra lengvai pastebimi naudojant dabartinius įprastus analizės metodus. CNN išmoksta ir atpažįsta bruožus, tokius kaip briaunos, tekstūros ir formos, gali prisitaikyti prie mastelio, orientacijos ir apšvietimo sąlygų skirtumų, todėl jie puikiai tinka atvaizdų klasifikavimui. Vaizdų analizė yra paremta patirtimi iš įvesties duomenų bazės. Taigi, CNN gebėjimas automatiškai išmokti sudėtingas vaizdų funkcijas daro juos galingu įrankiu įvairioms vaizdų analizės užduotims atlikti [9].

### 3.3 Duomenų rinkimas, apdorojimas ir iššūkiai

Kuriant mašininio mokymosi algoritmus, būtina surinkti dermoskopijos atvaizdų duomenų rinkinį. Tam reikia įsigyti įvairių ir reprezentatyvių paveikslų iš įvairių šaltinių, tokių kaip medicininiai

archyvai, tyrimų duomenų bazės ir klinikiniai tyrimai [15]. Šie atvaizdai turėtų apimti daugybę odos pažeidimų tipų, įskaitant melanomą, melanocitinius apgamus ir gerybinius pažeidimus, kad būtų užtikrinta visapusiška dermatologinių būklių aprėptis. Vienas reikšmingų iššūkių yra pažeidimo išvaizdos kintamumas: spalva, struktūra, kurios gali labai skirtis priklausomai nuo tokių veiksnių kaip odos ar pažeidimo tipas. Be to, dermoskopiniuose atvaizduose dažnai yra artefaktų, tokių kaip raukšlės, oro burbuliukai, plaukai ir atspindžiai, kurie gali trukdyti atlikti automatinę analizę ir klasifikaciją [10, 16]. Kitas aspektas yra klaidinančių požymių buvimas, kai gerybiniai pažeidimai gali turėti vaizdinį panašumą su piktybiniais, todėl gali būti klaidingai klasifikuojami [17]. Taip pat dermoskopijos atvaizduose gali būti subtilių ar ankstyvų melanomos požymių, kuriuos sunku aptikti, todėl klasifikavimo modeliams reikia didelio jautrumo ir specifiškumo. Todėl kuriant patikimus dermoskopinių atvaizdų analizės algoritmus reikia spręsti šiuos iššūkius naudojant pažangias išankstinio apdorojimo technologijas, didinimo strategijas ir sudėtingas gilaus mokymosi architektūras, pritaikytas dermoskopinio atvaizdo niuansams [11]. Klasifikuojant odos pažeidimus, yra svarbus išankstinis duomenų apdorojimas ir augmentacija: atvaizdo ryškumo, kontrasto, skiriamosios gebos standartizavimas, nepageidaujamų artefaktų sumažinimas. Be to, augmentacijos metodai sukuria daugiau duomenų, ir nauji atvaizdai atpažįstami taikant turimų vaizdų transformacijas [9]. Svarbų vaidmenį palengvinant prieigą prie aukštos kokybės dermoskopijos atvaizdų atlieka bendradarbiavimas su dermatologais, medicinos įstaigomis ir tyrimų organizacijomis. Šiuo metu plačiai naudojami yra HAM10000, ISIC ir PH<sup>2</sup> duomenų rinkiniai [11].

### 3.4 Konvoliucinių neuroninių tinklų modelių perspektyva

Keletas tyrimų įvertino konvoliucinių neuroninių tinklų modelių našumą ir tikslumą melanomos aptikimui. CNN šioje srityje parodė daug žadančių rezultatų dėl savo gebėjimo automatiškai išmokti paternus iš turimų vaizdų, todėl jie puikiai tinka atlikti tokias užduotis kaip odos pažeidimų klasifikavimas. Novatoriškame Han, S. S. ir kt. tyrime, parodomas konvoliucinių neuronų tinklų veiksmingumas diagnozuojant odos vėžį. Apmokytas naudojant platų duomenų rinkinį, kurį sudaro 129 450 klinikinių vaizdų, CNN modelis pasiekė išskirtinį jautrumą ir specifiškumą – atitinkamai 90,0 ir 92,1 %, ir įrodė gebėjimą atskirti melanomą nuo gerybinių darinių. Kiti tyrimai palygino dermatologų galimybes su CNN [12]. Kitame, lyginamajame tyrime, buvo naudojamas 100 vaizdų rinkinys (I lygis: tik dermoskopija; II lygis: dermoskopija ir klinikinė informacija). I lygyje dermatologai pasiekė vidutinį jautrumą ir specifiškumą atitinkamai 86,6 ir 71,3 %. Įvedus daugiau klinikinės informacijos (II lygis), jautrumas padidėjo iki 88,9 %, o specifiškumas - iki 75,7 %. CNN I lygyje jautrumas ir specifiškumas reikšmingai pranoko dermatologų rezultatus (86,6 ir 82,5 % atitinkamai) bei II lygyje reikšmingai pranoko jautrumą (88,9 %). Reiktų paminėti, jog CNN diagnostikos rezultatai buvo pranašesni už daugumą, bet ne visus dermatologus [13]. Kitoje perspektyvinėje diagnostinėje studijoje, 22 dermatologai, turintys skirtingą dermoskopijos naudojimo patirtį, 188 pacientams atliko viso kūno ištyrimą. Dermatologai nurodė įtartinų pažeidimų piktybiškumo lygį ir pasiūlė gydymo planą. Po šio tyrimo pacientai buvo išsiųsti į atskirą patalpą CNN vertinimui, o rezultatai buvo perduoti dermatologams, kurių buvo paprašyta iš naujo įvertinti savo sprendimus remiantis CNN pateiktomis išvadomis. Vertinant atskirai, dermatologų išvados jautrumu

buvo panašios į CNN; tačiau CNN aplenkė dermatologus specifiškumu ir tikslumu. Dar svarbiau, kad kai dermatologai įtraukė CNN rezultatus į savo sprendimų priėmimą, jautrumas padidėjo iki 100 %. Be to, įtraukus CNN rezultatus, nereikalingų gerybinių nevių pašalinimų skaičius sumažėjo 19,2 %. Autoriai pažymėjo, kad CNN rezultatų pridėjimas daugiausia buvo naudingas dermatologams, turintiems mažiau nei 5 metų patirtį [14].

### 4. Išvados

Dirbtinio intelekto integravimas į dermatologijos praktiką sukelia perversmą nustatant ir diagnozuojant odos ligas, tokias kaip melanoma. Konvoliuciniai neuroniniai tinklai parodė išskirtinį našumą analizuodami dermoskopinius vaizdus ir atskirdami gerybinius pažeidimus nuo piktybinių. Iššūkiai, tokie kaip duomenų kintamumas ir klaidinantys melanomos požymiai, turi būti sprendžiami naudojant pažangius išankstinio apdorojimo metodus ir augmentacijos strategijas. Tyrimai pabrėžia, kad dermatologai gali pagerinti savo diagnostikos galimybes bendradarbiaudami su CNN, ypač tie, kurie turi ribotą dermoskopijos patirtį. Šiuose tyrimuose atskleista žmogaus ir mašininio mokymosi metodų kombinacija žada geresnes pacientų ligos išeitis per tikslesnius ir veiksmingesnius diagnostikos procesus. Kadangi melanomos dažnis ir toliau didėja, dirbtinio intelekto naudojimas taps dar svarbesnis, kad pacientams visame pasaulyje būtų suteikta greitesnė ir tikslesnė diagnozė, o tai galiausiai pagerintų ligos išeitis.

### Literatūros šaltiniai

1. Stanienda-Sokol, K., Salwowska, N., Slawinska, M., Wicherska-Pawlowska, K., Lorenc, A., Wcislo-Dziadecka, D., Wydmanski, J., & Majewski, W. (2017). Primary Locations of Malignant Melanoma

- Lesions Depending on Patients' Gender and Age. Asian Pacific Journal of Cancer Prevention, 18(11).
2. Heistein JB, Acharya U, Mukkamalla SKR. Malignant Melanoma. [Updated 2023 May 22]. In: StatPearls [Internet]. Treasure Island (FL): StatPearls Publishing; 2024
3. Sonthalia S, Yumeen S, Kaliyadan F. Dermoscopy Overview and Extradagnostic Applications. [Updated 2023 Aug 8]. In: StatPearls [Internet]. Treasure Island (FL): StatPearls Publishing; 2024
4. Marghoob, Nadeem G., Liopyris, Konstantinos and Jaimes, Natalia. "Dermoscopy: A Review of the Structures That Facilitate Melanoma Detection" *Journal of Osteopathic Medicine*, vol. 119, no. 6, 2019, pp. 380-390.
5. Chan, H.-P., Samala, R. K., Hadjiiski, L. M., & Zhou, C. (2020). Deep Learning in Medical Image Analysis. In *Advances in Experimental Medicine and Biology* (pp. 3–21). Springer International Publishing.
5. Buch J, Criton S. Dermoscopy Saga - A Tale of 5 Centuries. *Indian J Dermatol*. 2021 Mar-Apr;66(2):174-178. doi: 10.4103/ijd.IJD\_691\_18. PMID: 34188274; PMCID: PMC8208256.
6. Waqar S, George S, Jean-Baptiste W, Yusuf Ali A, Inyang B, Koshy FS, George K, Poudel P, Chalasani R, Goonathilake MR, Mohammed L. Recognizing Histopathological Simulators of Melanoma to Avoid Misdiagnosis. *Cureus*. 2022 Jun 20;14(6):e26127. doi: 10.7759/cureus.26127. PMID: 35875272; PMCID: PMC9299949.
7. Culllell-Dalmau, M., Noé, S., Otero-Viñas, M., Meic, I., & Manzo, C. (2021). Convolutional Neural Network for Skin Lesion Classification: Understanding the Fundamentals Through Hands-On Learning. In *Frontiers in Medicine* (Vol. 8). Frontiers Media SA.
8. Alzubaidi, L., Zhang, J., Humaidi, A. J., Al-Dujaili, A., Duan, Y., Al-Shamma, O., Santamaría, J., Fadhel, M. A., Al-Amidie, M., & Farhan, L. (2021). Review of deep learning: concepts, CNN architectures, challenges, applications, future directions. In *Journal of Big Data* (Vol. 8, Issue 1). Springer Science and Business Media LLC.
9. Maron RC, Hekler A, Krieghoff-Henning E, Schmitt M, Schlager JG, Utikal JS, Brinker TJ Reducing the Impact of Confounding Factors on Skin Cancer Classification via Image Segmentation: Technical Model Study<sup>[11]</sup>. *Med Internet Res* 2021;23(3):e21695
10. A. Naeem, M. S. Farooq, A. Khelifi and A. Abid, "Malignant Melanoma Classification Using Deep Learning: Datasets, Performance Measurements, Challenges and Opportunities," in *IEEE Access*, vol. 8, pp. 110575-110597, 2020,
11. Han, S. S., Kim, M. S., Lim, W., Park, G. H., Park, I., & Chang, S. E. (2018). *Classification of the Clinical Images for Benign and Malignant Cutaneous Tumors Using a Deep Learning Algorithm. Journal of Investigative Dermatology*, 138(7), 1529–1538.
12. Haenssle HA, Fink C, Schneiderbauer R, Toberer F, Buhl T, Blum A, Kalloo A, Hassen ABH, Thomas L, Enk A, Uhlmann L; Reader study level-I and level-II Groups; Alt C, Arenbergerova M, Bakos R, Baltzer A, Bertlich I, Blum A, Bokor-Billmann T, Bowling J, Braghiroli N, Braun R, Buder-Bakhaya K, Buhl T, Cabo H, Cabrijan L, Cevic N, Classen A, Deltgen D, Fink C, Georgieva I, Hakim-Meibodi LE, Hanner S, Hartmann F, Hartmann J, Haus G, Hoxha E, Karls R, Koga H, Kreusch J, Lallas A, Majenka P, Marghoob A, Massone C, Mekokishvili L, Mestel D, Meyer V, Neuberger A, Nielsen K, Oliviero M, Pampena R, Paoli J, Pawlik E, Rao B, Rendon A, Russo T, Sadek A, Samhaber K, Schneiderbauer R, Schweizer A, Toberer F, Trennheuser L, Vlahova L, Wald A, Winkler J, Wölbing P, Zalaudek I. Man against machine: diagnostic performance of a deep learning

convolutional neural network for dermoscopic melanoma recognition in comparison to 58 dermatologists. *Ann Oncol*. 2018 Aug 1;29(8):1836-1842.

13. Winkler JK, Blum A, Kommoss K, Enk A, Toberer F, Rosenberger A, Haenssle HA. Assessment of Diagnostic Performance of Dermatologists Cooperating with a Convolutional Neural Network in a Prospective Clinical Study: Human With Machine. *JAMA Dermatol*. 2023 Jun 1;159(6):621-627. doi: 10.1001/jamadermatol.2023.0905. PMID: 37133847; PMCID: PMC10157508.

14. Pham, T.-C., Luong, C.-M., Visani, M., & Hoang, V.-D. (2018). Deep CNN and Data Augmentation for Skin Lesion Classification. In *Intelligent Information and Database Systems* (pp. 573–582). Springer International Publishing.

15. Raval, D., & Undavia, J. N. (2023). A Comprehensive assessment of Convolutional Neural Networks for skin and oral cancer detection using medical images. In *Healthcare Analytics* (Vol. 3, p. 100199). Elsevier BV.

16. Kaur R, GholamHosseini H, Sinha R, Lindén M. Melanoma Classification Using a Novel Deep Convolutional Neural Network with Dermoscopic Images. *Sensors (Basel)*. 2022 Feb 2;22(3):1134.