

Doktori (PhD) értekezés tézisei

**TÖBBCÍMKÉS MÉLYTANULÓ
HÁLÓZATOK OPTIMALIZÁLÁSA ORVOSI
KÉPFELDOLGOZÁSI FELADATOKRA**

KATONA TAMÁS

TÉMAVEZETŐ: DR. HARANGI BALÁZS



**DEBRECENI EGYETEM
INFORMATIKAI TUDOMÁNYOK DOKTORI ISKOLA
DEBRECEN, 2024.**

Tartalomjegyzék


1. Bevezetés	1
1.1. Használt adatkészletek	3
2. Többcímkes osztályozó építése	5
3. Hiperoptimalizált osztályozó építése többcímkes osztályozásra	7
4. Ensemble osztályozó építése kombinált veszteség függvénnyel többcímkes osztályozásra	10
Publikációs jegyzék	12
Irodalomjegyzék	13

1 Bevezetés


Ezen PhD disszertációban a többcímkes osztályozás problémakörével foglalkozunk mellkasröntgenfelvételeken. A mellkasi röntgenfelvételek fontos szerepet játszanak a diagnosztikában, mivel sok betegség diagnosztizálásának alapjai lehetnek. Számos előnye van, mint például az alacsony sugárterhelés, a könnyű hozzáférhetőség és az olcsó előállítás [1]. Ezek a felvételek lehetővé teszik a különböző betegségek, mint például tüdőfertőzések, tüdőgyulladások, szívproblémák és bizonyos ráktípusok diagnosztizálását. A WHO adatai szerint évente több mint négy-millió ember meghal tüdőgyulladásban, ami világszinten az összes halálozás 7%-át teszi ki [2].

Bár az Egyesült Államokban növekszik a radiológusok száma [1], sok országban, például Libériában, súlyos a szakemberhiány [3]. Ennek következtében késések jelentkezhetnek a betegek diagnosztizálásában és kezelésében. A sürgősségi osztályokon különösen nagy a kereslet a mellkasi röntgenfelvételek iránt, és a radiológusok számának növekedése nem tud lépést tartani a kereslettel [4].


A mellkasi röntgenfelvételek számítógéppel történő elemzése összetett kihívást jelent, mivel gyakran többféle patológiát tartalmaznak. Ami egy különleges többcímkes osztályozási problémához vezet. Például a jelen disszertációban is használt Chest X-ray14 adatkészlet [5], minden egyes képet több, főként a tüdőt és a szívet érintő patológiával annotáltak (lásd 1.1. ábra), számszerűen 14 különböző elváltozást címkéz. A korábbi tanulmányokban (melyeket később részletezünk) a különböző patológiák egyenlő súlyt kapnak az osztályozási folyamatban, és minden



(a)



(b)



(c)



(d)

1.1. ábra. Mellkasi röntgenfelvételek elváltozásokkal: **(a)** nincs elváltozás; **(b)** kardiomegália, konszolidáció, ödéma; **(c)** kardiomegália; **(d)** atelektázia

betegséget azonos fontossággal kezelnek a röntgenképek címkézésekor.

Ezzel szemben meg kell jegyeznünk, hogy a címkék között gyakran léteznek összefüggések, ilyen például a kardiomegália jelenléte, amely gyakran a tüdőödéma előfordulásának nagyobb kockázatával jár együtt, ami arra utal,

hogy a patológiák közötti összefüggések feltárása és megértése kulcsfontosságú lehet az osztályozási pontosság javításához. Míg azonban ezek a korrelációk bizonyos esetekben segíthetnek a diagnózis tisztázásában, a nem kapcsolódó címkék zajt vihetnek a rendszerbe, ami megnehezíti az osztályozó számára a releváns jellemzők azonosítását és a hatékony tanulást.

Ebben a kutatásban kizárólag a képadatokra összpontosítunk, és nem használunk semmilyen további külső információt, például a beteg nemét, korát vagy a fókuszálást segítő kiemelt részek koordinátáit, amelyekről más tanulmányokban kimutatták, hogy javítják a osztályozó modell teljesítményét.

1.1. Használt adatkészletek

A disszertációban két független többcímkes mellkasröntgen adatkészletet használtunk. A ChestX-ray14 [5] adatbázis 112 120 frontális nézetű röntgenfelvételt tartalmaz, amelyeket 14 különböző mellkasi patológiával, mint például tüdőgyulladás, ödéma és pneumothorax címkéztek. Ez az adathalmaz lehetővé teszi a képfeldolgozó algoritmusok széles körű tesztelését és validálását valós orvosi képeken. A MIMIC-CXR [6, 7] adatbázis még nagyobb, 371 920 frontális és laterális felvétellel rendelkezik, amely mélyebb betekintést nyújt a mellkasi diagnosztikába és szélesebb spektrumú patológiákba.

Célkitűzéseink

A kutatásunk célkitűzései a következők:

- Javítani az osztályozási teljesítményét és növelni a modell általánosítási képességét a Chest X-ray14 adatbázison, a MIMIC-CXR által biztosított tudás felhasználásával.
- Különböző optimalizációs algoritmusok hatásának vizsgálata ismert architektúrákon többcímkes környezetben.
- Új osztályozó réteg fejlesztése ismert CNN architektúrákra, a teljesítmény növelése érdekében.
- Kifejleszteni egy új online ensemble technikát kép-osztályozási feladatokhoz, amely kombinált veszteségfüggvényt alkalmaz az együttes és az egyes modellek komponensek veszteségeinek számítására.

2 Többcímkes osztályozó építése

Ebben a fejezetben egy többcímkes osztályozó rendszert építünk fel az alapoktól. Az egyik leggyakrabban alkalmazott megközelítést használjuk: a konvolúciós neurális hálózatokat (CNN-ek).

A konvolúciós neurális hálók speciális mélytanulási modellek, amelyek különösen hatékonyak a képfeldolgozás terén. A CNN-ek automatikusan megtanulják és kinyerik a képek legfontosabb jellemzőit, így nincs szükségük manuális jellemző kinyerésére. A rétegek hierarchikus felépítése lehetővé teszi, hogy az egyszerűbb mintázatoktól kezdve egyre összetettebb jellemzőket ismerjenek fel, mint például éleket, textúrákat és komplex alakzatokat. Ezáltal a CNN-ek különösen jól alkalmazhatók orvosi képfeldolgozási feladatokban, mint például a mellkas röntgenfelvételek elemzésére.

A többcímkes osztályozás több független bináris osztályozó együttesét jelenti, ezért az általunk továbbiakban használt veszteségfüggvényt a bináris keresztentrópiából vezetjük le. Ebben a módosításban a veszteségfüggvényt minden címkére függetlenül alkalmaztuk. Ez a független kezelés lehetővé teszi, hogy a modell minden egyes címkét külön bináris osztályozási problémaként tanuljon.

1. tézis. *Megadtunk egy veszteségfüggvényt, amely az önálló független címkek egyéni bináris keresztentrópiájának átlagát veszi. Valamint megmutattuk, hogy ez a módosított keresztentrópia alkalmas többcímkes osztályozásra. [12, 13]*

A többcímkes osztályozást először egy manuálisan összerakott CNN architektúrával teszteltünk, ebben a sza-

kaszban különböző mélységű és kernel számú konvolúciós blokkokat helyeztünk egymásra VGG [14] szerű architektúrával. Az így felvázolt modellek képesek voltak hatékonyan tanulni és az alapvető adatkészleti eredménynél jobb eredményt produkálni [5].

2. tézis. *Kifejlesztettünk egy minimális paraméterszámú, VGG-hez hasonló architektúrát, amely hatékonyan képes címkézni a mellkasi röntgenfelvételeket. Megmutattuk, hogy az új konvolúciós neurális hálózatunk alacsony paraméter szám mellett megőrzi a magas osztályozási pontosságot és hatékonyságot, így kiválóan alkalmazható orvosi képalkotási feladatokban. [12]*

3 Hiperoptimalizált osztályozó építése többcímkes osztályozásra

A disszertáció 4. fejezetében a transzfer tanulást kombináljuk hiperoptimalizációs technikával és ennek segítségével adunk meg egy új és jobb módszert a többcímkes röntgenfelvételek osztályozására. Ehhez jól ismert konvolúciós neurális hálózatokra, hiperoptimalizálás segítségével építünk új osztályozó részt.

Ezt a folyamatot négy fázisra bontottuk, az átláthatóság érdekében. Az első fázisban, néhány jól ismert architektúra gyors tesztelését végeztük el a MIMIC-CXR-adatkészlet részhalmazán. Az első lépés célja, hogy az adott CNN architektúra alkalmas-e többcímkes osztályozásra röntgenképek esetén. A használt jól ismert architektúrák (VGG [14], ResNet [15], DenseNet [16]) alapvetően kategorikus osztályozásra lettek kifejlesztve az ImageNet adatbázison. Ezen periódusban az ImageNet-en betanított súlyokkal inicializált modellt tanítjuk tovább, így hamar láthatóvá válik, hogy képes-e tanulni.

Ezt követő fázisban kiválasztottuk a legjobb konfigurációt, amit a teljes MIMIC-CXR-adatkészleten tanítottunk, ezzel elkészítve a saját előtanított súlyainkat a további fázisokhoz.

A 3. fázisban már az összehasonlíthatósághoz kiválasztott ChestX-ray14 adatbázist használjuk. Ebben a lépésben teljesen eltávolítjuk a nyertes CNN architektúra osztályozó részét és hiperoptimalizáló algoritmus segítségével új osztályozó részt építünk rá.

Az utolsó a 4. fázisban a nyertes hiperparaméterek használatával elvégeztük az ajánlott modell tanítását a hi-

vatalos adatkészlet szeleteken, hogy összehasonlíthatóvá váljon a módszerünk a legkorszerűbb algoritmusokkal. Végetül a végleges modell javulását Grad-Cam [17] módszer segítségével vizualizáljuk.

A jelen fejezet egy mélytanulási alternatívára összpontosít, automatizált jellemző-kivonással. Több publikáció is rendelkezésre áll, amelyek a többcímkes mellkasi röntgenfelvételek osztályozásával foglalkoznak: Wang és mtsai. [5] klasszikus mélytanulási architektúrák mellkasi röntgenfelvételekhez való használatát írták le. Egy másik kutatócsoport, Rajpurkar és mtsai. [18] a jól ismert architektúrát, a DenseNet121-et használta a jellemző kivonatolásához, és csak az utolsó teljesen összekapcsolt réteget változtatta meg, hogy alkalmazkodjon a többcímkes osztályozás sajátosságaihoz.

Néhányan további adatokat használnak a címkéhez; Wang és mtsai. [19] külső radiológiai jelentéseket használtak a teljesítmény javítása érdekében, Tang és mtsai. [20] pedig a radiológiai jelentésekből kinyert súlyossági szintek segítségével azonosították a betegség kategóriákat. Yao és mtsai. [21] szintén a DenseNet-et használták; ők azonban kódolóként használták, és dekódolóként a LSTM-mel kombinálták.

A jelenlegi legmodernebb architektúrák átfogó áttekintése azt mutatja, hogy a jól ismert CNN-ek jellemzői extrakciós rétegeinek módosítására összpontosítanak. Bár ezek a megközelítések természetesen előrelépést jelentenek a többcímkes osztályozási területen, a szakirodalom áttekintése azt mutatja, hogy a hálózatok osztályozó kompo-

nensének változtatásai egy alul kutatott terület, ezért mi most ebben mélyedünk el.

3. tézis. *Kifejlesztettünk egy komplex, több fázisból álló módszert, amely a transzfer tanulást hiperparaméter-optimalizációval kombinálja, ezáltal hatékonyabb címkézést biztosít, mint a jelenleg elérhető legjobb megoldások. [13]*

4 Ensemble osztályozó építése kombinált veszteség függvénnyel többcímkes osztályozásra

Az előző fejezetekben ismertetett munkánk és irodalmi áttekintésünk egyaránt egytagú CNN modelleket használt a röntgenfelvételek címkézésére. Számos valós probléma esetében azonban egyetlen monolitikus rendszer kapacitása nem elegendő. Ezt felismerve mind természetes, mind mesterséges rendszerek több, egymással összekapcsolt alrendszert alkalmaznak a komplexitás csökkentése és az összetett kihívások hatékony megoldása érdekében.

A neurális hálózati együttesek létrehozásának módszertana változó. A leggyakrabban használt megközelítés egy kétlépcsős (offline) folyamat, amelyet Sharkey és mtsai. [22] írtak le. Az első lépésben egyedi hálózatokat hoznak létre, majd azokat kombinálják, de a hálózatok közötti interakció lehetősége elvész. Az egylépéses (online) modellekben az egyes hálózatokat egyidejűleg tanítják, ami lehetővé teszi a modellek közötti közvetlen interakciókat és visszajelzéseket, növelve az előrejelzési pontosságot és a robusztusságot [23, 24, 25].

A disszertáció 4. fejezetében egy új online ensemble technikát mutatunk be, képosztályozási feladatokhoz. Újításunk kulcsa egy speciális kombinált veszteségfüggvény, amely külön-külön számítja ki az ensemble modell és a résztvevő modellkomponensek veszteségét. Több előre betanított CNN-t egyesítünk, és különböző kombinációs módszereket alkalmazunk, például teljesen összekapcsolt rétegeken keresztül történő összekapcsolást és címke-sú-

lyozott átlagolást. Az utóbbi módszerben a paraméterek megtanulhatók. A ensemblek felállítása során számos architektúrát vizsgáltunk meg: ResNet [15], DenseNet [16], InceptionV3 [26], MobileNet [27], a RegNet [28] és az Xception [29].

Emellett olyan stratégiát is alkalmazunk, ahol az egyes tagmodellek kimeneti rétegeit az egyesített veszteségfüggvény kiszámítására használjuk, míg a jellemzőkinyerő rétegeket egy új, teljesen összekapcsolt réteghez kapcsoljuk. Ez a megközelítés javítja az osztályozási teljesítményt és növeli a modell általánosítási képességét.

4. tézis. *Kifejlesztettünk egy új, kombinált veszteségfüggvényt, amely az egyes hálózati tagok egyedi veszteségét integrálja a hálózat teljes veszteségével. Megmutattuk, hogy ez a megközelítés lehetővé teszi, hogy a különböző architektúrájú tagok teljesítményét együttesen optimalizálja, ami jelentős javulást eredményez az osztályozási hatékonyságban. Megmutattuk azt is, hogy az új veszteségfüggvényünk a vizsgált adathalmazok jelentős részében jobb teljesítményt nyújtott a bevezetett súlyozott átlag ensemble architektúra estén, mint a jelenleg elérhető legjobb megoldások, mivel lokálisan is finomhangolja a hálózat minden komponensét a globális célok eléréséhez. [30]*

Publikációs jegyzék

Folyóirat cikkek

Katona, T., Tóth, G., Petró, M., & Harangi, B. (2024). Advanced Multi-label Image Classification Techniques Using Ensemble Methods. *Machine Learning and Knowledge Extraction, Mach. Learn. Knowl. Extr.* 2024, 6(2), 1281-1297;

Katona, T., Tóth, G., Petró, M., & Harangi, B. (2024). Developing New Fully Connected Layers for Convolutional Neural Networks with Hyperparameter Optimization for Improved Multi-Label Image Classification. *Mathematics*, 12(6), 806.

Konferencia cikkek

Katona, T., & Antal, B. (2019, September). Automated analysis of radiology images using convolutional neural networks. In 2019 11th International Symposium on Image and Signal Processing and Analysis (ISPA) (pp. 89-92). IEEE.

Egyéb közlemények (nem része a disszertációnak)

Rebenku, I., Bartha, F. A., **Katona, T.**, Zsebik, B., Antalffy, G., Takács, L., ... & Vereb, G. (2023). Taking molecular pathology to the next level: Whole slide multicolor confocal imaging with the Panoramic Confocal digital pathology scanner. *Cytometry Part A*, 103(3), 198-207.

Besenczi, R., **Katona, T.**, & Szilágyi, M. (2015, October). A fork implementation of the Police Edition of the OOCWC system. In 2015 6th IEEE International Conference on Cognitive Infocommunications (CogInfoCom) (pp. 163-164). IEEE.

Irodalomjegyzék

- [1] Rosenkrantz, A.B.; Hughes, D.R.; Duszak, R., Jr. The U.S. Radiologist Workforce: An Analysis of Temporal and Geographic Variation by Using Large National Datasets. *Radiology* **2016**, *279*, 175-184, doi:10.1148/radiol.2015150921.
- [2] Ruuskanen, O.; Lahti, E.; Jennings, L.C.; Murdoch, D.R. Viral pneumonia. *Lancet* **2011**, *377*, 1264-1275. [https://doi.org/10.1016/S0140-6736\(10\)61459-6](https://doi.org/10.1016/S0140-6736(10)61459-6).
- [3] Ali, F.; Harrington, S.; Kennedy, S.; Hussain, S. Diagnostic radiology in Liberia: A country report. *J. Glob. Radiol.* **2015**, *1*, 1-7. <https://doi.org/10.7191/jgr.2015.1020>.
- [4] Fatihoglu, E.; Aydin, S.; Gokharman, F.D.; Ece, B.; Kosar, P.N. X-ray use in chest imaging in emergency department on the basis of cost and effectiveness. *Acad. Radiol.* **2016**, *23*, 1239-1245. <https://doi.org/10.1016/j.acra.2016.05.008>.
- [5] Wang, X.; Peng, Y.; Lu, L.; Lu, Z.; Bagheri, M.; Summers, R.M. Chestx-ray8: Hospital-scale chest x-ray database and benchmarks on weakly-supervised classification and localization of common thorax diseases. In Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR 2017), Honolulu, HI, USA, 21-26 July, 2017; pp. 3462-3471.
- [6] Johnson, A.E.W.; Pollard, T.J.; Berkowitz, S.J.; Greenbaum, N.R.; Lungren, M.P.; Deng, C.Y.; Mark, R.G.; Horng, S. MIMIC-CXR, a de-identified publicly available database of chest radiographs with free-text reports. *Sci. Data* **2019**, *6*, 317. <https://doi.org/10.1038/s41597-019-0322-0>.
- [7] Johnson, A.E.W.; Pollard, T.J.; Greenbaum, N.R.; Lungren, M.P.; Ying Deng, C.; Peng, Y.; Lu, Z.; Mark, R.G.; Berkowitz, S.J.; Horng, S. MIMIC-CXR-JPG, a large publicly available database of labeled chest radiographs. *arXiv* **2019**, arXiv:1901.07042.
- [8] Kruger, R.P.; Townes, J.R.; Hall, D.L.; Dwyer, S.J.; Lodwick, G.S. Automated Radiographic Diagnosis via Feature Extraction and Classification of Cardiac Size and Shape Descriptors. *IEEE Trans. Biomed. Eng.* **1972**, *BME-19*, 174-186. <https://doi.org/10.1109/TBME.1972.324115>.
- [9] Lodwick, G.S.; Keats, T.E.; Dorst, J.P. The Coding of Roentgen Images for Computer Analysis as Applied to Lung Cancer. *Radiology* **1963**, *81*, 185-200. <https://doi.org/10.1148/81.2.185>.
- [10] Meyers, P.H.; Nice, C.M.; Becker, H.C.; Nettleton, W.J.; Sweeney, J.W.; Meckstroth, G.R. Automated Computer Analysis of Radiographic Images. *Radiology* **1964**, *83*, 1029-1034. <https://doi.org/10.1148/83.6.1029>.

- [11] de Bruijne, M. Machine learning approaches in medical image analysis: From detection to diagnosis. *Med. Image Anal.* **2016**, *476*, 94–97. <https://doi.org/10.1016/j.media.2016.06.032>.
- [12] Katona, T.; Antal, B. Automated analysis of radiology images using Convolutional Neural Networks. In Proceedings of the 2019 11th International Symposium on Image and Signal Processing and Analysis (ISPA 2019), Dubrovnik, Croatia, 23–25 September 2019; pp. 89–92. <https://doi.org/10.1109/ISPA.2019.8868764>.
- [13] Katona, T.; Tóth, G.; Petró, M.; Harangi, B. Developing New Fully Connected Layers for Convolutional Neural Networks with Hyperparameter Optimization for Improved Multi-Label Image Classification. *Mathematics* **2024**, *12*, 806. <https://doi.org/https://doi.org/10.3390/math12060806>.
- [14] Simonyan, K.; Zisserman, A. Very Deep Convolutional Networks for Large-Scale Image Recognition. *arXiv* **2015**. <https://arxiv.org/abs/1409.1556>
- [15] He, K.; Zhang, X.; Ren, S.; Sun, J. Deep Residual Learning for Image Recognition. *arXiv* **2015**. <https://arxiv.org/abs/1512.03385>
- [16] Huang, G.; Liu, Z.; van der Maaten, L.; Weinberger, K.Q. Densely Connected Convolutional Networks. *arXiv* **2018**, arXiv:1608.06993.
- [17] Selvaraju, R.R.; Cogswell, M.; Das, A.; Vedantam, R.; Parikh, D.; Batra, D. Grad-CAM: Visual Explanations from Deep Networks via Gradient-Based Localization. *Int. J. Comput. Vis.* **2020**, *128*, 336–359, <https://doi.org/10.1007/s11263-019-01228-7>.
- [18] Irvin, J.; Rajpurkar, P.; Ko, M.; Yu, Y.; Ciurea-Ilcus, S.; Chute, C.; Marklund, H.; Haghighi, B.; Ball, R.; Shpanskaya, K.; et al. CheXpert: A Large Chest Radiograph Dataset with Uncertainty Labels and Expert Comparison. In Proceedings of the AAAI Conference on Artificial Intelligence 2019, Honolulu, HI, USA, 27 January–1 February 2019; pp. 590–597.
- [19] Wang, X.; Peng, Y.; Lu, L.; Lu, Z.; Summers, R.M. TieNet: Text-Image Embedding Network for Common Thorax Disease Classification and Reporting in Chest X-Rays. In Proceedings of the 2015 IEEE Conference on Computer Vision and Pattern Recognition (CVPR 2018), Salt Lake City, UT, USA, 18 June–22 June 2018; pp. 9049–9058.

- [20] Tang, Y.; Wang, X.; Harrison, A.P.; Lu, L.; Xiao, J.; Summers, R.M. Attention-guided curriculum learning for weakly supervised classification and localization of thoracic diseases on chest radiographs. In Proceedings of the International Workshop on Machine Learning in Medical Imaging (MLMI 2018), Granada, Spain, 16 September 2018; Springer: Berlin/Heidelberg, Germany 2018; Volume 1; pp. 249–258.
- [21] Yao, L.; Prosky, J.; Poblenz, E.; Covington, B.; Lyman, K. Weakly supervised medical diagnosis and localization from multiple resolutions. *arXiv* **2018**, arXiv:1803.07703.
- [22] Sharkey, Amanda J. C. On combining artificial neural nets. **Connection science** **1996**: 299-314.
- [23] Dvornik, N.; Mairal, J.; Schmid, C. Diversity With Cooperation: Ensemble Methods for Few-Shot Classification. In Proceedings of the 2019 IEEE/CVF International Conference on Computer Vision (ICCV), Seoul, Republic of Korea, 27 October–2 November 2019; pp. 3722–3730. <http://dx.doi.org/10.1109/ICCV.2019.00382>
- [24] Opitz, M.; Waltner, G.; Possegger, H.; Bischof, H. Deep Metric Learning with BIER: Boosting Independent Embeddings Robustly. *IEEE Trans. Pattern Anal. Mach. Intell.* **2020**, *42*, 276–290. <http://dx.doi.org/10.1109/TPAMI.2018.2848925>
- [25] Zhang, L.; Shi, Z.; Cheng, M.M.; Liu, Y.; Bian, J.W.; Zhou, J.T.; Zheng, G.; Zeng, Z. Nonlinear Regression via Deep Negative Correlation Learning. *IEEE Trans. Pattern Anal. Mach. Intell.* **2021**, *43*, 982–998. <http://dx.doi.org/10.1109/ACCESS.2019.2933670>
- [26] Szegedy, C.; Vanhoucke, V.; Ioffe, S.; Shlens, J.; Wojna, Z. Rethinking the Inception Architecture for Computer Vision, *arXiv* **2015**. <https://arxiv.org/abs/1512.00567>
- [27] Sandler, M.; Howard, A.; Zhu, M.; Zhmoginov, A.; Chen, L.-C. MobileNetV2: Inverted Residuals and Linear Bottlenecks *arXiv* **2018**. <https://arxiv.org/abs/1801.04381>
- [28] Radosavovic, I.; Kosaraju, R.P.; Girshick, R.; He, K.; Dollár, P. Designing Network Design Spaces *arXiv* **2020**. <https://arxiv.org/abs/2003.13678>
- [29] Chollet, F. Xception: Deep Learning with Depthwise Separable Convolutions *arXiv* **2017**. <https://arxiv.org/abs/1610.02357>

- [30] Katona, T.; Tóth, G.; Petró, M.; Harangi, B. Advanced Multi-label Image Classification Techniques Using Ensemble Methods. *MAKE 2024*, **Bírálat alatt.**



Nyilvántartási szám: DEENK/359/2024.PL
Tárgy: PhD Publikációs Lista

Jelölt: Katona Tamás

Doktori Iskola: Informatikai Tudományok Doktori Iskola

MTMT azonosító: 10058278

A PhD értekezés alapjául szolgáló közlemények

Idegen nyelvű tudományos közlemények külföldi folyóiratban (2)

1. **Katona, T.**, Tóth, G., Petró, M., Harangi, B.: Advanced Multi-Label Image Classification Techniques Using Ensemble Methods.
Mach. Learn. Knowl. Extr. 6 (2), 1281-1297, 2024. EISSN: 2504-4990.
DOI: <https://doi.org/10.3390/make6020060>
IF: 3.9 (2022)
2. **Katona, T.**, Tóth, G., Petró, M., Harangi, B.: Developing New Fully Connected Layers for Convolutional Neural Networks with Hyperparameter Optimization for Improved Multi-Label Image Classification.
Mathematics. 12 (6), 1-16, 2024. EISSN: 2227-7390.
DOI: <http://dx.doi.org/10.3390/math12060806>
IF: 2.4 (2022)

Idegen nyelvű konferencia közlemények (1)

3. **Katona, T.**, Antal, B.: Automated analysis of radiology images using Convolutional Neural Networks.
In: Proceedings of the 11th International Symposium on Image and Signal Processing and Analysis. Eds.: Lončarić S., Bregović R., Carli M., Subašić M, University of Zagreb, Dubrovnik, 89-92, 2019. ISBN: 9781728131405





További közlemények

Idegen nyelvű tudományos közlemények külföldi folyóiratban (1)

4. Rebenku, I., Bartha, F., **Katona, T.**, Zsebik, B., Antalffy, G., Takács, L., Molnár, B., Vereb, G.:
Taking molecular pathology to the next level: whole slide multicolor confocal imaging with the
Pannoramic Confocal digital pathology scanner.
Cytom. Part A. 103 (3), 198-207, 2023. ISSN: 1552-4922.
DOI: <http://dx.doi.org/10.1002/cyto.a.24675>
IF: 3.7 (2022)

Magyar nyelvű absztrakt kiadványok (2)

5. **Katona, T.**: Konfokális fluoreszcenciás patológiai szkennerek alkalmazhatósága molekuláris
kölsönhatásokon alapuló diagnosztikára.
Orvosképzés. 92 (2), 410, 2017. ISSN: 0030-6037.
6. **Katona, T.**: Fluoreszcencia élettartam és teljes belső visszaverődés mikroszkóp integrált
számítógépes vezérlése.
Orvosképzés. 90 (2), 350, 2015. ISSN: 0030-6037.

Idegen nyelvű absztrakt kiadványok (1)

7. Besenczi, R., **Katona, T.**, Szilágyi, M.: A fork implementation of the police edition of the OOCWC
system.
In: 6th IEEE Conference on Cognitive Infocommunications CogInfoCom 2015 : Proceedings,
October 19-21, 2015, Széchenyi István University Győr, Hungary, IEEE, Danvers, 163-164,
2015. ISBN: 9781467381284

A közlő folyóiratok összesített impakt faktora: 10

**A közlő folyóiratok összesített impakt faktora (az értekezés alapján szolgáló közleményekre):
6,3**

A DEENK a Jelölt által az iDEa Tudóstérbe feltöltött adatok bibliográfiai és tudományometriai
ellenőrzését a tudományos adatbázisok és a Journal Citation Reports Impact Factor lista alapján
elvégezte.

Debrecen, 2024.06.13.



**Short thesis for the degree of
doctor of philosophy (PhD)**

OPTIMIZATION OF MULTI-LABEL
DEEP LEARNING NETWORKS FOR
MEDICAL IMAGE PROCESSING TASKS

TAMÁS KATONA

SUPERVISOR: DR. BALÁZS HARANGI



UNIVERSITY OF DEBRECEN
DOCTORAL SCHOOL OF INFORMATICS
DEBRECEN, 2024.

Contents


1	Introduction	20
1.1	Used datasets	22
2	Construction of a multi-label classifier	24
3	Building a hyperoptimized classifier for multi-label classification	26
4	Building an ensemble classifier with combined loss function for multi-label classification	28
	List of Publications	30
	Bibliography	31

1 Introduction


In this PhD dissertation, we address the problem of multi-label classification in chest radiographs. Chest radiographs play an important role in diagnostics as they can be the basis for the diagnosis of many diseases. They have many advantages, such as low radiation exposure, easy availability, and cheap production [1]. These scans allow the diagnosis of various diseases such as lung infections, pneumonia, heart problems, and certain types of cancer. According to the WHO, more than four million people die of pneumonia every year, accounting for 7% of all deaths worldwide [2]. Although the number of radiologists is increasing in the United States [1], many countries, such as Liberia, have a severe shortage of specialists [3]. Demand for chest X-rays is particularly high in emergency departments, and the increase in radiologists is not keeping pace with demand [4].

Computer analysis of chest X-rays is a complex challenge, as they often contain multiple pathologies. Which leads to a special multi-label classification problem. For example, in the ChestX-ray14 [5] dataset used in this dissertation, each image is annotated with several pathologies, mainly involving the lungs and heart (see Figure 1.1), numerically labeling 14 different lesions. In previous studies (detailed later), the different pathologies are given equal weight in the classification process and all pathologies are treated with equal importance when labeling radiographs.


Conversely, it should be noted that there are often associations between labels, such as the presence of cardiomegaly, which is often associated with an increased risk of pulmonary edema, suggesting that identifying and understanding associations between pathologies may be



(a)



(b)



(c)



(d)

Figure 1.1: Chest X-ray images with with distinct conditions:: (a) no finding; (b) cardiomegaly, consolidation, edema; (c) cardiomegaly; (d) atelectasis.

key to improving classification accuracy. However, while these correlations can help clarify the diagnosis in some cases, unrelated labels can introduce noise into the system, making it difficult for the classifier to identify relevant features and learn effectively.

In this study, we focus only on the image data and do not use any additional external information, such as patient gender, age, or coordinates of the focal regions that have been shown in other studies to improve the performance of the classification model.

1.1 Used datasets

Two independent multi-label chest X-ray datasets were used in this dissertation. The ChestX-ray14 [5] database contains 112,120 frontal view radiographs labeled with 14 different chest pathologies such as pneumonia, edema, and pneumothorax. This dataset allows extensive testing and validation of image processing algorithms on real medical images. The MIMIC-CXR [6, 7] database is even larger, with 371,920 frontal and lateral images, providing deeper insights into thoracic diagnostics and a wider range of pathologies.

Our objectives

The objectives of our research are::

- Improve the classification performance and increase the generalization capability of the model on the ChestX-ray14 database using the knowledge provided by MIMIC-CXR.

- Investigating the impact of different optimization algorithms on known architectures in a multi-label environment.
- Development of a new classification layer for known CNN architectures to improve performance.
- To develop a new online ensemble technique for image classification tasks that uses a combined loss function which uses the ensemble loss and the members losses.

2 Construction of a multi-label classifier

In this chapter, we build a multi-label classification system from the ground up. We use one of the most commonly used approaches: convolutional neural networks (CNNs).

Convolutional neural networks are advanced deep learning models that are particularly efficient in image processing. CNNs automatically learn and extract the most important features of images, so they do not require manual feature extraction. The hierarchical structure of the layers allows them to learn increasingly complex features, such as edges, textures, and complex shapes, starting from simple patterns. This makes CNNs particularly well suited for medical image processing tasks such as the analysis of chest X-ray images.

Multi-label classification combines several independent binary classifiers, so we derive the loss function we will use from the binary cross-entropy. In this modification, the loss function is applied to each label independently. This independent treatment allows the model to learn each label as a separate binary classification problem.

Thesis 1. *We have given a loss function that takes the average of the individual binary cross-entropies of the independent independent tags. We also showed that this modified crossentropy is sub-optimal for multi-label classification. [12, 13]*

Multi-label classification was first tested with a manually assembled CNN architecture, at this stage we stacked convolutional blocks of different depths and kernel numbers using a VGG [14]-like architecture. The models thus sketched were able to learn efficiently and produce better

results than the basic measurement which was publicated with dataset [5].

Thesis 2. *We have developed a architecture with minimal parameters similar to VGG that can efficiently label chest X-rays. We have demonstrated that our new convolutional neural network optimizes the number of parameters while maintaining high classification accuracy and efficiency, making it an excellent candidate for medical imaging tasks.*
[12]

3 Building a hyperoptimized classifier for multi-label classification

In Chapter 4 of this dissertation, we combine transfer learning with hyperparameter optimization techniques to provide a new and improved method for classifying multi-label X-ray images. For this purpose, we build a new classifier on well-known convolutional neural networks using hyperoptimization.

This process has been broken down into four phases for transparency. In the first phase, we performed a quick test of some well-known architectures on a subset of the MIMIC-CXR dataset. The first step is to test whether a given CNN architecture is suitable for the multi-label classification of X-ray images. The well-known architectures used (VGG [14], ResNet [15], DenseNet [16]) were developed for categorical classification on the ImageNet database. In this period, the model initialized with weights trained on ImageNet will be trained further, so that it will be quickly seen whether it can learn.

In a subsequent phase, we selected the best configuration to be trained on the full MIMIC-CXR dataset, thus creating our pre-trained weights for the subsequent phases.

In phase 3, we use the ChestX-ray14 database, which has been selected for comparability. In this step, we completely remove the classifier part of the winning CNN architecture and build a new classifier part on top of it using a hyper-optimization algorithm.

In the last phase 4, we used the obtained hyperparameters to train the proposed model on the official dataset slices to make our method comparable with state-of-the-art algorithms. Finally, we visualize the improvement of the

final model using the Grad-Cam[17] method.

This chapter focuses on a deep learning alternative with automated feature extraction. Several publications are available that deal with the classification of multi-label chest radiographs: Wang et al. [5] described the use of classical deep learning architectures for chest radiographs. Another researchers, Rajpurkar et al. [18] used the well-known architecture DenseNet121 for feature extraction and only changed the last fully connected layer to adapt to the multi-label classification.

Some have used additional data for labeling; Wang et al. [19] used external radiology reports to improve performance, and Tang et al. [20] used severity levels extracted from radiology reports to identify disease categories.

A comprehensive review of current state-of-the-art architectures shows that the features of well-known CNNs focus on modifying their extraction layers. While these approaches certainly represent an advance in the multi-label classification field, a review of the literature shows that changes to the classification component of networks are an under-researched area, and we now delve into this.

Thesis 3. *We have developed a complex, multi-phase method that combines transfer learning with hyperparameter optimization to provide more efficient labeling than the best currently available solutions. We demonstrated that our new method develops an optimized classifier part on top of the pre-learned convolutional feature extraction part, maximizing classification performance. [13]*

4 Building an ensemble classifier with combined loss function for multi-label classification

Our work and literature review in the previous chapters both used single-member CNN models to label X-ray images. However, for many real-world problems, the capacity of a single monolithic system is not sufficient. Recognizing this, both natural and artificial systems employ multiple interconnected subsystems to reduce complexity and efficiently solve the combined challenges.

The methodology for creating neural network ensembles varies. The most commonly used approach is a two-step (offline) process described by Sharkey et al. [22] In the first step, individual networks are created and then combined, but the possibility of interaction between networks is lost. In one-step (online) models, individual networks are trained simultaneously, allowing direct interactions and feedback between models, increasing prediction accuracy and robustness [23, 24, 25].

In Chapter 4 of this dissertation, we present a new online ensemble technique for image classification tasks. The key to our innovation is a special combined loss function that separately computes the loss of the ensemble model and the participating model components. We merge several pre-trained CNNs and apply different combination methods, such as fully coupled through-layer coupling and label-weighted averaging. In the latter method, the parameters can be learned. In setting up the ensembles, we have explored several architectures ResNet [15], DenseNet [16], InceptionV3 [26], MobileNet [27], RegNet [28] and Xcep-

tion [29]

We also employ a strategy where the output layers of each member model are used to compute the merged loss function, while the feature extraction layers are merged into a new, fully coupled layer. This approach improves the classification performance and increases the model's generalization ability.

Thesis 4. *We developed a new combined loss function that integrates the individual loss of each network member with the total loss of the network. We show that this approach allows to jointly optimize the performance of members with different architectures, resulting in significant improvements in classification efficiency. We also show that our new loss function performed better than the best currently available solutions for a significant fraction of the datasets studied under the introduced weighted-average ensemble architecture, as it also locally fine-tunes all components of the network to achieve global goals. [30]*

List of Publications

Journal articles

Katona, T., Tóth, G., Petró, M., & Harangi, B. (2024). Advanced Multi-label Image Classification Techniques Using Ensemble Methods. *Machine Learning and Knowledge Extraction, Mach. Learn. Knowl. Extr.* 2024, 6(2), 1281-1297;

Katona, T., Tóth, G., Petró, M., & Harangi, B. (2024). Developing New Fully Connected Layers for Convolutional Neural Networks with Hyperparameter Optimization for Improved Multi-Label Image Classification. *Mathematics*, 12(6), 806.

Conference publications

Katona, T., & Antal, B. (2019, September). Automated analysis of radiology images using convolutional neural networks. In 2019 11th International Symposium on Image and Signal Processing and Analysis (ISPA) (pp. 89-92). IEEE.

Other publications (not part of the thesis)

Rebenku, I., Bartha, F. A., **Katona, T.**, Zsebik, B., Antalffy, G., Takács, L., ... & Vereb, G. (2023). Taking molecular pathology to the next level: Whole slide multicolor confocal imaging with the Panoramic Confocal digital pathology scanner. *Cytometry Part A*, 103(3), 198-207.

Besenczi, R., **Katona, T.**, & Szilágyi, M. (2015, October). A fork implementation of the Police Edition of the OOCWC system. In 2015 6th IEEE International Conference on Cognitive Infocommunications (CogInfoCom) (pp. 163-164). IEEE.

Bibliography

- [1] Rosenkrantz, A.B.; Hughes, D.R.; Duszak, R., Jr. The U.S. Radiologist Workforce: An Analysis of Temporal and Geographic Variation by Using Large National Datasets. *Radiology* **2016**, *279*, 175-184, doi:10.1148/radiol.2015150921.
- [2] Ruuskanen, O.; Lahti, E.; Jennings, L.C.; Murdoch, D.R. Viral pneumonia. *Lancet* **2011**, *377*, 1264–1275. [https://doi.org/10.1016/S0140-6736\(10\)61459-6](https://doi.org/10.1016/S0140-6736(10)61459-6).
- [3] Ali, F.; Harrington, S.; Kennedy, S.; Hussain, S. Diagnostic radiology in Liberia: A country report. *J. Glob. Radiol.* **2015**, *1*, 1–7. <https://doi.org/10.7191/jgr.2015.1020>.
- [4] Fatihoglu, E.; Aydin, S.; Gokharman, F.D.; Ece, B.; Kosar, P.N. X-ray use in chest imaging in emergency department on the basis of cost and effectiveness. *Acad. Radiol.* **2016**, *23*, 1239–1245. <https://doi.org/10.1016/j.acra.2016.05.008>.
- [5] Wang, X.; Peng, Y.; Lu, L.; Lu, Z.; Bagheri, M.; Summers, R.M. Chestx-ray8: Hospital-scale chest x-ray database and benchmarks on weakly-supervised classification and localization of common thorax diseases. In Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR 2017), Honolulu, HI, USA, 21–26 July, 2017; pp. 3462–3471.
- [6] Johnson, A.E.W.; Pollard, T.J.; Berkowitz, S.J.; Greenbaum, N.R.; Lungren, M.P.; Deng, C.Y.; Mark, R.G.; Horng, S. MIMIC-CXR, a de-identified publicly available database of chest radiographs with free-text reports. *Sci. Data* **2019**, *6*, 317. <https://doi.org/10.1038/s41597-019-0322-0>.
- [7] Johnson, A.E.W.; Pollard, T.J.; Greenbaum, N.R.; Lungren, M.P.; Ying Deng, C.; Peng, Y.; Lu, Z.; Mark, R.G.; Berkowitz, S.J.; Horng, S. MIMIC-CXR-JPG, a large publicly available database of labeled chest radiographs. *arXiv* **2019**, arXiv:1901.07042.
- [8] Kruger, R.P.; Townes, J.R.; Hall, D.L.; Dwyer, S.J.; Lodwick, G.S. Automated Radiographic Diagnosis via Feature Extraction and Classification of Cardiac Size and Shape Descriptors. *IEEE Trans. Biomed. Eng.* **1972**, *BME-19*, 174–186. <https://doi.org/10.1109/TBME.1972.324115>.
- [9] Lodwick, G.S.; Keats, T.E.; Dorst, J.P. The Coding of Roentgen Images for Computer Analysis as Applied to Lung Cancer. *Radiology* **1963**, *81*, 185–200. <https://doi.org/10.1148/81.2.185>.
- [10] Meyers, P.H.; Nice, C.M.; Becker, H.C.; Nettleton, W.J.; Sweeney, J.W.; Meckstroth, G.R. Automated Computer Analysis of Radiographic Images. *Radiology* **1964**, *83*, 1029–1034. <https://doi.org/10.1148/83.6.1029>.

- [11] de Bruijne, M. Machine learning approaches in medical image analysis: From detection to diagnosis. *Med. Image Anal.* **2016**, *476*, 94–97. <https://doi.org/10.1016/j.media.2016.06.032>.
- [12] Katona, T.; Antal, B. Automated analysis of radiology images using Convolutional Neural Networks. In Proceedings of the 2019 11th International Symposium on Image and Signal Processing and Analysis (ISPA 2019), Dubrovnik, Croatia, 23–25 September 2019; pp. 89–92. <https://doi.org/10.1109/ISPA.2019.8868764>.
- [13] Katona, T.; Tóth, G.; Petró, M.; Harangi, B. Developing New Fully Connected Layers for Convolutional Neural Networks with Hyperparameter Optimization for Improved Multi-Label Image Classification. *Mathematics* **2024**, *12*, 806. <https://doi.org/https://doi.org/10.3390/math12060806>.
- [14] Simonyan, K.; Zisserman, A. Very Deep Convolutional Networks for Large-Scale Image Recognition. *arXiv* **2015**. <https://arxiv.org/abs/1409.1556>
- [15] He, K.; Zhang, X.; Ren, S.; Sun, J. Deep Residual Learning for Image Recognition. *arXiv* **2015**. <https://arxiv.org/abs/1512.03385>
- [16] Huang, G.; Liu, Z.; van der Maaten, L.; Weinberger, K.Q. Densely Connected Convolutional Networks. *arXiv* **2018**, arXiv:1608.06993.
- [17] Selvaraju, R.R.; Cogswell, M.; Das, A.; Vedantam, R.; Parikh, D.; Batra, D. Grad-CAM: Visual Explanations from Deep Networks via Gradient-Based Localization. *Int. J. Comput. Vis.* **2020**, *128*, 336–359, <https://doi.org/10.1007/s11263-019-01228-7>.
- [18] Irvin, J.; Rajpurkar, P.; Ko, M.; Yu, Y.; Ciurea-Ilcus, S.; Chute, C.; Marklund, H.; Haghgoo, B.; Ball, R.; Shpanskaya, K.; et al. CheXpert: A Large Chest Radiograph Dataset with Uncertainty Labels and Expert Comparison. In Proceedings of the AAAI Conference on Artificial Intelligence 2019, Honolulu, HI, USA, 27 January–1 February 2019; pp. 590–597.
- [19] Wang, X.; Peng, Y.; Lu, L.; Lu, Z.; Summers, R.M. TieNet: Text-Image Embedding Network for Common Thorax Disease Classification and Reporting in Chest X-Rays. In Proceedings of the 2015 IEEE Conference on Computer Vision and Pattern Recognition (CVPR 2018), Salt Lake City, UT, USA, 18 June–22 June 2018; pp. 9049–9058.
- [20] Tang, Y.; Wang, X.; Harrison, A.P.; Lu, L.; Xiao, J.; Summers, R.M. Attention-guided curriculum learning for weakly supervised classification and localization of thoracic diseases on chest radiographs. In Proceedings of the International

- Workshop on Machine Learning in Medical Imaging (MLMI 2018), Granada, Spain, 16 September 2018; Springer: Berlin/Heidelberg, Germany 2018; Volume 1; pp. 249–258.
- [21] Yao, L.; Prosky, J.; Poblenz, E.; Covington, B.; Lyman, K. Weakly supervised medical diagnosis and localization from multiple resolutions. *arXiv* **2018**, arXiv:1803.07703.
- [22] Sharkey, Amanda J. C. On combining artificial neural nets. *Connection science* **1996**: 299-314.
- [23] Dvornik, N.; Mairal, J.; Schmid, C. Diversity With Cooperation: Ensemble Methods for Few-Shot Classification. In Proceedings of the 2019 IEEE/CVF International Conference on Computer Vision (ICCV), Seoul, Republic of Korea, 27 October–2 November 2019; pp. 3722–3730. <http://dx.doi.org/10.1109/ICCV.2019.00382>
- [24] Opitz, M.; Waltner, G.; Possegger, H.; Bischof, H. Deep Metric Learning with BIER: Boosting Independent Embeddings Robustly. *IEEE Trans. Pattern Anal. Mach. Intell.* **2020**, *42*, 276–290. <http://dx.doi.org/10.1109/TPAMI.2018.2848925>
- [25] Zhang, L.; Shi, Z.; Cheng, M.M.; Liu, Y.; Bian, J.W.; Zhou, J.T.; Zheng, G.; Zeng, Z. Nonlinear Regression via Deep Negative Correlation Learning. *IEEE Trans. Pattern Anal. Mach. Intell.* **2021**, *43*, 982–998. <http://dx.doi.org/10.1109/ACCESS.2019.2933670>
- [26] Szegedy, C.; Vanhoucke, V.; Ioffe, S.; Shlens, J.; Wojna, Z. Rethinking the Inception Architecture for Computer Vision, *arXiv* **2015**. <https://arxiv.org/abs/1512.00567>
- [27] Sandler, M.; Howard, A.; Zhu, M.; Zhmoginov, A.; Chen, L.-C. MobileNetV2: Inverted Residuals and Linear Bottlenecks *arXiv* **2018**. <https://arxiv.org/abs/1801.04381>
- [28] Radosavovic, I.; Kosaraju, R.P.; Girshick, R.; He, K.; Dollár, P. Designing Network Design Spaces *arXiv* **2020**. <https://arxiv.org/abs/2003.13678>
- [29] Chollet, F. Xception: Deep Learning with Depthwise Separable Convolutions *arXiv* **2017**. <https://arxiv.org/abs/1610.02357>
- [30] Katona, T.; Tóth, G.; Petró, M.; Harangi, B. Advanced Multi-label Image Classification Techniques Using Ensemble Methods. *MAKE* **2024**, *Bírálat alatt.*



Registry number: DEENK/359/2024.PL
Subject: PhD Publication List

Candidate: Tamás Katona
Doctoral School: Doctoral School of Informatics
MTMT ID: 10058278

List of publications related to the dissertation

Foreign language scientific articles in international journals (2)

1. **Katona, T.**, Tóth, G., Petró, M., Harangi, B.: Advanced Multi-Label Image Classification Techniques Using Ensemble Methods.
Mach. Learn. Knowl. Extr. 6 (2), 1281-1297, 2024. EISSN: 2504-4990.
DOI: <https://doi.org/10.3390/make6020060>
IF: 3.9 (2022)
2. **Katona, T.**, Tóth, G., Petró, M., Harangi, B.: Developing New Fully Connected Layers for Convolutional Neural Networks with Hyperparameter Optimization for Improved Multi-Label Image Classification.
Mathematics. 12 (6), 1-16, 2024. EISSN: 2227-7390.
DOI: <http://dx.doi.org/10.3390/math12060806>
IF: 2.4 (2022)

Foreign language conference proceedings (1)

3. **Katona, T.**, Antal, B.: Automated analysis of radiology images using Convolutional Neural Networks.
In: Proceedings of the 11th International Symposium on Image and Signal Processing and Analysis. Eds.: Lončarić S., Bregović R., Carli M., Subašić M, University of Zagreb, Dubrovnik, 89-92, 2019. ISBN: 9781728131405





List of other publications

Foreign language scientific articles in international journals (1)

4. Rebenku, I., Bartha, F., **Katona, T.**, Zsebik, B., Antalffy, G., Takács, L., Molnár, B., Vereb, G.:
Taking molecular pathology to the next level: whole slide multicolor confocal imaging with the
Pannoramic Confocal digital pathology scanner.
Cytom. Part A. 103 (3), 198-207, 2023. ISSN: 1552-4922.
DOI: <http://dx.doi.org/10.1002/cyto.a.24675>
IF: 3.7 (2022)

Hungarian abstracts (2)

5. **Katona, T.**: Konfokális fluoreszcenciás patológiai szkennel alkalmazhatósága molekuláris
köcsönhatásokon alapuló diagnosztikára.
Orvosképzés. 92 (2), 410, 2017. ISSN: 0030-6037.
6. **Katona, T.**: Fluoreszcencia élettartam és teljes belső visszaverődés mikroszkóp integrált
számítógépes vezérlése.
Orvosképzés. 90 (2), 350, 2015. ISSN: 0030-6037.

Foreign language abstracts (1)

7. Besenczi, R., **Katona, T.**, Szilágyi, M.: A fork implementation of the police edition of the OOCWC
system.
In: 6th IEEE Conference on Cognitive Infocommunications CogInfoCom 2015 : Proceedings,
October 19-21, 2015, Széchenyi István University Győr, Hungary, IEEE, Danvers, 163-164,
2015. ISBN: 9781467381284

Total IF of journals (all publications): 10

Total IF of journals (publications related to the dissertation): 6,3

The Candidate's publication data submitted to the iDEa Tudóstér have been validated by DEENK on
the basis of the Journal Citation Report (Impact Factor) database.

13 June, 2024

