

Deteksi Leukemia Limfoblastik Akut menggunakan Convolutional Neural Network

Mutaqin Akbar¹, Putri Taqwa Prasetyaningrum², Putry Wahyu Setyaningsih³, Moh Ahsan⁴, Alexius Endy Budianto⁵

¹Program Studi Informatika, Universitas Mercu Buana Yogyakarta, Yogyakarta, Indonesia, 55283
e-mail: ¹mutaqin@mercubuana-yogya.ac.id

^{2,3}Program Studi Sistem Informasi, Universitas Mercu Buana Yogyakarta, Yogyakarta, Indonesia, 55283
e-mail: ²putri@mercubuana-yogya.ac.id, ³putryws@mercubuana-yogya.ac.id

^{4,5}Program Studi Teknik Informatika, Universitas PGRI Kanjuruhan Malang, Malang, Indonesia, 65148
e-mail: ⁴ahsan@unikama.ac.id, ⁵endybudianto@unikama.ac.id

Submitted Date: September 14th, 2024
Revised Date: January 25th, 2024

Reviewed Date: January 13th, 2024
Accepted Date: January 29th, 2024

Abstract

Acute lymphoblastic leukemia is the most important type of childhood leukemia, and accounts for 25% of childhood cancers. Accurately differentiating normal cell precursors from cancer cells is key to the diagnosis of acute lymphoblastic leukemia (ALL). However, under a microscope, cancer cells are so similar to normal cells that it is difficult to classify them. This article presents a detection of acute lymphoblastic leukemia using Convolutional Neural Network (CNN). The dataset which is obtained from ALL_IDB is 582 color image data which is divided into 482 training image data and 100 testing image data. The image data will be resized to 128x128x3 before being input to the CNN model. The CNN model used in this study is a multi-scale CNN which consists of 3 convolution layers (filter size of 3x3, number of filters for each convolution layer is 32, 64, and 128 respectively, and ReLU activation function), 3 subsampling layers using maxpool with filter size of 2x2 , 1 concatenate layer is used to combine the output of each subsampling layer, 1 fully-connected layer with a softmax activation function and a cross-entropy error function, and finally an output layer with 2 classes, namely normal cells and cancer cells. The CNN model will be trained using the Adam optimizer training algorithm with a training rate of 0.0002 and iterated 20 times. Based on the training results after iterating 20 times, the smallest error value was obtained, namely 0.0001 and the largest accuracy value, namely 100% in the 20th epoch. The CNN model was then tested with 100 testing image data and obtained an accuracy rate of 98% and an error value of 0.0482.

Keywords: acute lymphoblastic leukemia; classification; convolutional neural network

Abstrak

Leukemia limfoblastik akut merupakan jenis leukemia anak yang paling penting, dan menyumbang 25% dari kanker anak. Membedakan secara akurat prekursor sel normal dari sel kanker adalah kunci diagnosis leukemia limfoblastik akut. Namun, di bawah mikroskop, sel kanker sangat mirip dengan sel normal sehingga sulit untuk mengklasifikasikannya. Artikel ini menyajikan deteksi sel leukemia limfoblastik akut menggunakan Convolutional Neural Network (CNN). Dataset diperoleh dari ALL_IDB sejumlah 582 data citra berwarna yang dibagi menjadi 482 data citra latih dan 100 data citra uji. Data citra tersebut akan diubah ukurannya menjadi 128x128x3 sebelum akhirnya menjadi masukan dari model CNN. Model CNN yang digunakan adalah multi-scale CNN yang terdiri dari 3 lapisan konvolusi (ukuran filter 3x3, jumlah filter untuk masing-masing lapisan konvolusi yakni berurutan 32, 64, dan 128, dan fungsi aktivasi ReLU), 3 lapisan *subsampling* menggunakan maxpool dengan ukuran filter 2x2, 1 lapisan



penggabungan yang digunakan untuk menggabungkan keluaran dari masing-masing lapisan *subsampling*, 1 lapisan fully-connected dengan fungsi aktivasi softmax dan fungsi galat cross-entropy, dan terakhir lapisan keluaran dengan jumlah kelas 2 yakni sel normal dan sel kanker. Model CNN akan dilatih menggunakan algoritma pelatihan Adam optimizer dengan laju pelatihan 0.0002 dan dilakukan iterasi sebanyak 20 kali. Berdasarkan hasil pelatihan setelah diiterasi sebanyak 20 kali, didapatkan nilai galat terkecil yakni 0,0001 dan nilai akurasi terbesar yakni 100% pada epoch ke-20. Model CNN kemudian diuji dengan 100 data citra uji dan menghasilkan tingkat akurasi 98% dan nilai galat 0,0482.

Keywords: convolutional neural network; klasifikasi; leukemia limfoblastik akut

1. Pendahuluan

Leukemia adalah tumor jahat hematologis yang disebabkan oleh duplikat jahat sel darah putih yang belum matang di sumsum tulang. Leukemia dapat dibagi menjadi leukemia akut dan leukemia kronis. Leukemia kronis biasanya memiliki masa serangan yang lama. Sebagai jenis leukemia akut, leukemia limfoblastik akut atau dalam Bahasa Inggris disebut *acute lymphoblastic leukemia* (ALL) adalah jenis leukemia anak yang paling penting, dan menyumbang 25% dari kanker anak (Fujita et al., 2021). Dalam perkembangan lebih dari 50 tahun, pengobatan leukemia limfoblastik akut telah membuat kemajuan besar. Dengan perlakuan khusus pada tahap awal, tingkat respons lengkap awal dapat mencapai lebih dari 70% (Li & Wang, 2020). Oleh karena itu, sangat penting untuk melakukan diagnosis leukemia limfoblastik akut pada tahap awal serangannya. Secara umum, metode diagnostik utama leukemia limfoblastik akut adalah melalui morfologi. Ketika ada sejumlah besar sel B-limfoblas (sel kanker) di sumsum tulang, dapat didiagnosis sebagai leukemia limfoblastik akut (Puckett & Chan, 2023). Membedakan secara akurat prekursor sel normal dari sel kanker adalah kunci diagnosis leukemia limfoblastik akut. Namun, di bawah mikroskop, sel kanker sangat mirip dengan sel normal sehingga sulit untuk mengklasifikasikannya.

Teknologi visi komputer telah banyak membantu dalam diagnosis penyakit dan menjadi arah penelitian menjanjikan dalam beberapa tahun ini. Dalam teknologi visi komputer, pengenalan citra melalui *deep learning* merupakan salah satu metode yang penting. Salah satu jaringan saraf yang paling sering digunakan dalam *deep learning* yakni *Convolutional Neural Network* (CNN). CNN memiliki kemampuan belajar mandiri yang kuat, kemampuan adaptif, dan kemampuan generalisasi. Metode pengenalan citra tradisional memerlukan

ekstraksi fitur dan klasifikasi manual, sedangkan CNN hanya membutuhkan data citra sebagai input jaringan, dan kemampuan belajar mandiri jaringan dapat menyelesaikan klasifikasi citra (Akbar, 2021). Penggunaan CNN *multichannel* untuk mengidentifikasi radiografi dada dan mendiagnosa pneumonia telah dilakukan dan tingkat akurasi klasifikasi radiografi dada mencapai 97,92%, yang memberikan metode deteksi yang sangat andal (Nahid et al., 2020). Penggabungan metode *deep learning* untuk mengekstraksi fitur gambar dan ekstraksi manual untuk memproses gambar USG payudara untuk mengklasifikasikan tumor payudara juga telah dilakukan. Rata-rata tingkat akurasi klasifikasi mencapai 96,1% yang berarti kanker payudara dapat dideteksi secara akurat dengan citra USG payudara (Daoud et al., 2020). *Deep learning* diterapkan untuk pengenalan kanker kandung kemih, dan tingkat akurasi pengenalan dalam aplikasi praktis mencapai 83,36%. Hasil ini membuktikan efektivitas *deep learning* dalam diagnosis kanker kandung kemih (Yang et al., 2021).

Selanjutnya, ada beberapa penelitian yang menggunakan teknologi visi komputer untuk mendiagnosa leukemia. Penggunaan *deep learning* dengan CNN untuk klasifikasi ALL dengan tingkat akurasi 97,78% (Rehman et al., 2018). Algoritma pembelajaran mesin dan CNN digunakan untuk mengklasifikasikan empat jenis leukemia, dengan akurasi tertinggi 88,25% (Ahmed et al., 2019). Arsitektur CNN AlexNet juga digunakan dan ditambahkan 2 lapisan *fully-connected* untuk klasifikasi subtipen ALL. Tingkat akurasi deteksi leukemia dan klasifikasi subtipen ALL masing-masing yaitu 99,5% dan 96,06% (Shafique & Tehsin, 2018).

Algoritma pembelajaran mesin untuk mendiagnosa leukemia akut berdasarkan gambar darah dan sekelilingnya juga diusulkan. Pengelompokan warna dan morfologi matematika



digunakan untuk mengelompokkan gambar, dan kemudian algoritma pembelajaran mesin digunakan untuk mengklasifikasikan enam jenis sel. Tingkat akurasi klasifikasi sel mencapai 85,8%, dan tingkat diagnosis yang tepat untuk leukemia mencapai 94% (Boldú et al., 2019). Penggabungan dua model NASNet-Large dan VGG19 diusulkan untuk mengklasifikasikan sel leukemia B-limfoblas dan sel prekursor B-limfoid normal dengan tingkat akurasi klasifikasi 96,58%, yang dapat secara akurat mendiagnosis leukemia limfoblastik akut dan membuktikan bahwa model gabungan tersebut lebih efektif daripada model jaringan tunggal (Kasani et al., 2020).

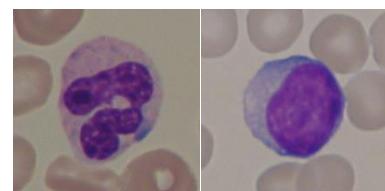
ViT-CNN yang merupakan model gabungan dari model transformator visi dan CNN juga diusulkan. ViT-CNN digunakan untuk memilah sel normal dan sel kanker dengan tingkat akurasi mencapai 99,03% (Jiang et al., 2021). Kemudian, ALLNET yang telah dimodifikasi digunakan untuk mendeteksi sel normal dan sel kanker dengan tingkat akurasi maksimum yang dicapai yaitu 95,54% (Sampathila et al., 2022).

Model yang digunakan pada penelitian ini berbasis CNN dengan memanfaatkan keluaran dari masing-masing lapisan konvolusi sehingga diharapkan fitur-fitur di setiap lapisan konvolusi dapat dijadikan sumber masukan pada proses pengenalan (Akbar et al., 2022).

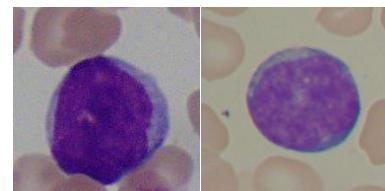
2. Metodologi

Dataset yang digunakan pada penelitian ini menggunakan ALL_IDB yang dikumpulkan oleh Scotti dkk (Piuri & Scotti, 2004; Scotti, 2005, 2006; Labati et al., 2011; Genovese et al., 2021). Citra yang digunakan adalah citra sel normal dan sel kanker dalam basis data ALL_IDB2 yang terdiri

dari 260 citra. Kemudian dari basis data ALL_IDB1 disarikan beberapa data citra berdasarkan data koordinat letak sel normal maupun kanker yang disediakan oleh Scotti dkk dan didapatkan sebanyak 322 citra. Sehingga keseluruhan data citra yang diakuisisi yakni sebanyak 582 citra. Contoh dataset dapat dilihat pada Gambar 1 dan Gambar 2. Dataset citra akan diubah ukuran piksel citranya menjadi 128x128 sebelum menjadi masukan (*input*) pada model CNN.

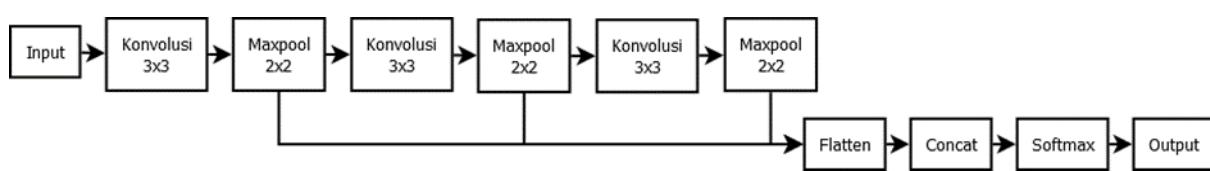


Gambar 1 Contoh sel normal



Gambar 2 Contoh sel kanker

Arsitektur CNN yang digunakan dapat dilihat pada Gambar 3. Arsitektur CNN yang digunakan terdiri dari yang pertama lapisan masukan, tiga lapisan konvolusi dan ditambahkan fungsi aktivasi *rectified linear unit* (ReLU), tiga lapisan *subsampling*, lapisan perataan (*flatten*), lapisan penggabungan (*concatenate* atau disingkat *concat*), lapisan klasifikasi (*fully-connected*), dan terakhir lapisan keluaran.



Gambar 3 Arsitektur CNN

Pada lapisan masukan merupakan data citra dengan ukuran 128x128x3. 128x128 merupakan ukuran piksel data citra dan 3 merupakan jumlah saluran warna (merah, hijau, dan biru). Kemudian pada lapisan konvolusi, terdapat tiga lapisan konvolusi dengan ukuran filter 3x3. Jumlah *filter* pada konvolusi pertama, kedua, ketiga yakni

masing-masing 32, 64, dan 128. Disetiap akhir dari lapisan konvolusi akan diberikan lapisan *subsampling* dengan fungsi *maxpool* untuk mengambil nilai terbesar dari sebuah jendela dengan ukuran 2x2.

Keluaran dari setiap lapisan *subsampling* akan masuk ke lapisan perataan yaitu mengubah

matriks menjadi vektor. Kemudian, semua output dari tiap lapisan *subsampling* (pertama, kedua, dan ketiga) digabungkan menjadi 1 vektor pada lapisan penggabungan. Keluaran dari lapisan penggabungan akan menjadi masukan pada lapisan terakhir yakni lapisan klasifikasi dengan menggunakan fungsi aktivasi *softmax*.

Fungsi galat yang digunakan adalah *cross entropy* (Janocha & Czarnecki, 2017). Untuk meminimalisir galat, digunakan algoritma pelatihan yakni *adaptive moment estimation* (Adam). Adam merupakan sebuah metode optimasi stokastik efisien yang hanya membutuhkan gradien orde pertama dengan sedikit kebutuhan memori. Adam menghitung laju pelatihan adaptif individual untuk parameter yang berbeda dari perkiraan momen pertama dan kedua dari gradien (Kingma & Ba, 2014).

3. Hasil dan Pembahasan

Dataset citra yang ada (sebanyak 582 citra) dibagi menjadi data citra latih dan data citra uji, dengan jumlah masing-masing yakni 482 dan 100. Data citra yang menjadi masukan berukuran 128x128 piksel dan memiliki 3 saluran warna (merah, hijau, dan biru), sehingga menjadi sebuah matriks dengan ukuran 128x128x3. Model CNN yang digunakan terdiri dari 3 lapisan konvolusi dengan 3 lapisan *subsampling* (maxpool). Disetiap lapisan konvolusi digunakan fungsi aktivasi ReLU. Keluaran dari setiap lapisan *subsampling* yang sudah melewati proses perataan (*flatten*) dari matriks menjadi vektor akan digabungkan menjadi 1 vektor dalam lapisan penggabungan (*concat*). Dan terakhir akan diklasifikasikan dengan fungsi aktivasi softmax.

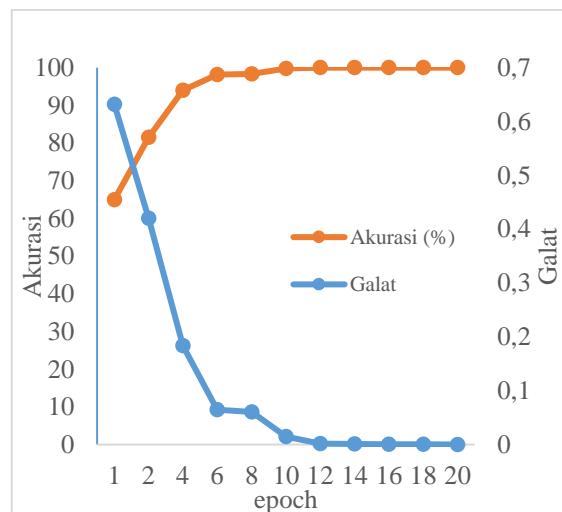
Pada proses pelatihan, digunakan laju pelatihan dan *epoch* atau iterasi yang digunakan dalam proses pelatihan adalah masing-masing 0,0002 dan 20. Ukuran *filter* yang digunakan untuk setiap lapisan konvolusi adalah 3x3 dengan jumlah filter yaitu 32, 64, dan 128. Ukuran jendela pada lapisan *subsampling* adalah 2x2. Berdasarkan Tabel 1, dapat dilihat bahwa pada *epoch* pertama model kesulitan mengenali dataset. Hal tersebut Nampak dari nilai akurasi yang rendah yaitu 64,94% dan nilai galat yang cukup besar yaitu 0,6321. Pada *epoch* ke-2 sampai ke-10, nilai galat turun cukup drastis pada *epoch* ke-2 dan *epoch* ke-3. Penurunan galat dari *epoch* ke-1 dan *epoch* ke-2 mencapai 0,2118, kemudian dari *epoch* ke-2 dan

ke-3 mencapai 0,1346. Dan nilai galat terus menerus turun sampai angka 0,015 pada *epoch* ke-10. Sementara nilai akurasinya terus meningkat mulai dari 81,54% pada *epoch* ke-2 sampai 99,79% pada *epoch* ke-10. Mulai dari *epoch* ke-11, model mampu mencapai nilai akurasi 100% dengan nilai galat yang sudah cukup kecil yaitu 0,004. Nilai galat tersebut mulai turun perlahan dan konvergen mulai *epoch* ke-15, dan nilai akurasi juga tetap pada angka 100% mulai dari *epoch* ke-11 sampai *epoch* ke-15. Pada *epoch* ke-16 sampai *epoch* ke-20, nilai galat turun tidak terlalu signifikan karena seperti disebutkan sebelumnya bahwa model sudah memasuki konvergen mulai *epoch* ke-15. Nilai galat yang dicapai pada *epoch* ke-20 yaitu 0,0001 dengan nilai akurasi 100%. Grafik galat dan akurasi dapat dilihat pada Gambar 4.

Tabel 1. Hasil pelatihan model

epoch	Galat	Akurasi (%)
1	0,6321	64,94
2	0,4203	81,54
3	0,2857	89,42
4	0,1837	93,98
5	0,1231	95,85
6	0,0646	98,13
7	0,0462	98,96
8	0,0606	98,34
9	0,0405	99,17
10	0,015	99,79
11	0,004	100
12	0,0018	100
13	0,0014	100
14	0,001	100
15	0,0007	100
16	0,0005	100
17	0,0003	100
18	0,0003	100
19	0,0002	100
20	0,0001	100





Gambar 4. Grafik galat dan akurasi

Pada proses pengujian dengan menggunakan 100 data citra uji, nilai galat yang diperoleh yaitu 0,0482. Sedangkan nilai akurasi yang diperoleh dari model CNN yang diusulkan mencapai 98%, yang artinya dari 100 data citra uji, hanya 2 citra yang salah dikenali.

Hasil tersebut tentunya masih dibawah penelitian yang dilakukan oleh Shafique dan Jiang (Shafique & Tehsin, 2018)(Jiang et al., 2021). Hal tersebut dapat dikarenakan perbedaan model dan dataset yang digunakan. Pada penelitian yang dilakukan oleh Shafique, dataset yang digunakan adalah dataset subtipe dari leukemia limfoblastik akut, sedangkan pada penelitian yang dilakukan oleh Jiang, dataset yang digunakan adalah dataset ISBI 2019 yang terdiri dari 10.661 data citra.

4. Kesimpulan

Deteksi leukemia limfoblastik akut menggunakan *Convolutional Neural Network* (CNN) telah disajikan dalam artikel ini. Model CNN yang digunakan terdiri dari masukan, 3 lapisan konvolusi, 3 lapisan *subsampling* (*maxpool*), lapisan perataan (*flatten*), lapisan penggabungan (*concat*), lapisan klasifikasi (*softmax*), dan keluaran. Lapisan penggabungan digunakan untuk menggabungkan keluaran dari setiap lapisan *subsampling*. Proses pelatihan model mampu mencapai nilai galat 0,0001 dan nilai akurasi 100% pada *epoch* ke-20. Dan pada proses pengujian didapatkan nilai akurasi pengujian mencapai 98% dengan nilai galat 0,0482.

Referensi

- Ahmed, N., Yigit, A., Isik, Z., & Alpkocak, A. (2019). Identification of Leukemia Subtypes from Microscopic Images Using Convolutional Neural Network. *Diagnostics (Basel, Switzerland)*, 9(3), 104. <https://doi.org/10.3390/diagnostics9030104>
- Akbar, M. (2021). Traffic sign recognition using convolutional neural networks. *Jurnal Teknologi Dan Sistem Komputer*, 9(2), 120–125. <https://doi.org/10.14710/jtsiskom.2021.13959>
- Akbar, M., Purnomo, A. S., & Supatman, S. (2022). Multi-Scale Convolutional Networks untuk Pengenalan Rambu Lalu Lintas di Indonesia. *Jurnal Sifokom (Sistem Informasi Dan Komputer)*, 11(3), 310–315. <https://doi.org/10.32736/sifokom.v11i3.1452>
- Boldú, L., Merino, A., Alférez, S., Molina, A., Acevedo, A., & Rodellar, J. (2019). Automatic recognition of different types of acute leukaemia in peripheral blood by image analysis. *Journal of Clinical Pathology*, 72(11), 755–761. <https://doi.org/10.1136/jclinpath-2019-205949>
- Daoud, M. I., Abdel-Rahman, S., Bdair, T. M., Al-Najar, M. S., Al-Hawari, F. H., & Alazrai, R. (2020). Breast Tumor Classification in Ultrasound Images Using Combined Deep and Handcrafted Features. *Sensors*, 20(23), 6838. <https://doi.org/10.3390/s20236838>
- Fujita, T. C., Sousa-Pereira, N., Amarante, M. K., & Watanabe, M. A. E. (2021). Acute lymphoid leukemia etiopathogenesis. *Molecular Biology Reports*, 48(1), 817–822. <https://doi.org/10.1007/s11033-020-06073-3>
- Genovese, A., Hosseini, M. S., Piuri, V., Plataniotis, K. N., & Scotti, F. (2021). Acute Lymphoblastic Leukemia Detection Based on Adaptive Unsharpening and Deep Learning. *ICASSP 2021 - 2021 IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP)*, 1205–1209. <https://doi.org/10.1109/ICASSP39728.2021.9414362>
- Janocha, K., & Czarnecki, W. M. (2017). *On Loss Functions for Deep Neural Networks in Classification* (arXiv:1702.05659). arXiv. <http://arxiv.org/abs/1702.05659>
- Jiang, Z., Dong, Z., Wang, L., & Jiang, W. (2021). Method for Diagnosis of Acute Lymphoblastic Leukemia Based on ViT-CNN Ensemble Model. *Computational Intelligence and Neuroscience*, 2021, 1–12. <https://doi.org/10.1155/2021/7529893>
- Kasani, P. H., Park, S.-W., & Jang, J.-W. (2020). An Aggregated-Based Deep Learning Method for Leukemic B-lymphoblast Classification. *Diagnostics (Basel, Switzerland)*, 10(12), 1064. <https://doi.org/10.3390/diagnostics10121064>



- Kingma, D. P., & Ba, J. (2014). *Adam: A Method for Stochastic Optimization.* <https://doi.org/10.48550/ARXIV.1412.6980>
- Labati, R. D., Piuri, V., & Scotti, F. (2011). All-IDB: The acute lymphoblastic leukemia image database for image processing. *2011 18th IEEE International Conference on Image Processing*, 2045–2048. <https://doi.org/10.1109/ICIP.2011.6115881>
- Li, L., & Wang, Y. (2020). Recent updates for antibody therapy for acute lymphoblastic leukemia. *Experimental Hematology & Oncology*, 9(1), 33. <https://doi.org/10.1186/s40164-020-00189-9>
- Nahid, A.-A., Sikder, N., Bairagi, A. K., Razzaque, Md. A., Masud, M., Z. Kouzani, A., & Mahmud, M. A. P. (2020). A Novel Method to Identify Pneumonia through Analyzing Chest Radiographs Employing a Multichannel Convolutional Neural Network. *Sensors*, 20(12), 3482. <https://doi.org/10.3390/s20123482>
- Piuri, V., & Scotti, F. (2004). Morphological classification of blood leucocytes by microscope images. *2004 IEEE International Conference on Computational Intelligence for Measurement Systems and Applications, 2004. CIMSA.*, 103–108. <https://doi.org/10.1109/CIMSA.2004.1397242>
- Puckett, Y., & Chan, O. (2023). Acute Lymphocytic Leukemia. In *StatPearls*. StatPearls Publishing. <http://www.ncbi.nlm.nih.gov/books/NBK459149/>
- Rehman, A., Abbas, N., Saba, T., Rahman, S. I. ur, Mehmood, Z., & Kolivand, H. (2018). Classification of acute lymphoblastic leukemia using deep learning. *Microscopy Research and Technique*, 81(11), 1310–1317. <https://doi.org/10.1002/jemt.23139>
- Sampathila, N., Chadaga, K., Goswami, N., Chadaga, R. P., Pandya, M., Prabhu, S., Bairy, M. G., Katta, S. S., Bhat, D., & Upadhy, S. P. (2022). Customized Deep Learning Classifier for Detection of Acute Lymphoblastic Leukemia Using Blood Smear Images. *Healthcare*, 10(10), 1812. <https://doi.org/10.3390/healthcare10101812>
- Scotti, F. (2005). Automatic morphological analysis for acute leukemia identification in peripheral blood microscope images. *CIMSA. 2005 IEEE International Conference on Computational Intelligence for Measurement Systems and Applications, 2005.*, 96–101. <https://doi.org/10.1109/CIMSA.2005.1522835>
- Scotti, F. (2006). Robust Segmentation and Measurements Techniques of White Cells in Blood Microscope Images. *2006 IEEE Instrumentation and Measurement Technology Conference Proceedings*, 43–48. <https://doi.org/10.1109/IMTC.2006.328170>
- Shafique, S., & Tehsin, S. (2018). Acute Lymphoblastic Leukemia Detection and Classification of Its Subtypes Using Pretrained Deep Convolutional Neural Networks. *Technology in Cancer Research & Treatment*, 17, 153303381880278. <https://doi.org/10.1177/1533033818802789>
- Yang, R., Du, Y., Weng, X., Chen, Z., Wang, S., & Liu, X. (2021). Automatic recognition of bladder tumours using deep learning technology and its clinical application. *The International Journal of Medical Robotics and Computer Assisted Surgery*, 17(2). <https://doi.org/10.1002/rcs.2194>

