

Prediksi Kondisi Kritis Anak di Ruang Intensif Melalui *Machine Learning*: Tinjauan Literatur

Desi Anggraini ¹⁾*, La Ode Abdul Rahman ²⁾

¹ Mahasiswa Magister Keperawatan Fakultas Ilmu Keperawatan, Universitas Indonesia

² Departemen DKKD Fakultas Ilmu Keperawatan, Universitas Indonesia

Depok, Jawa Barat

email: desi.anggraini11@ui.ac.id

ABSTRACT

Introduction: There's a lot of data that must be monitored and documented regarding children in critical condition in intensive rooms. Data is useful in nursing intervention. As technology progresses, patients' data in the hospital is recorded electronically and can be digitally processed to give information about a patient's predictive condition. One system for processing data is known as machine learning. **Method:** A literature review by analyzing data about using machine learning in systematically predicting children in critical conditions. **Purpose:** Provides an overview and idea from journal review of the use of machine learning in predicting critical conditions to children in the intensive room. **Result:** Based on a review of 10 selected journals, it is concluded that using machine learning in predicting a patient's critical condition is more accurate than the conventional model. **Recommendations:** Hoped use of machine learning can be more developed in the pediatric intensive care unit that requires fast and accurate action.

Keywords: Machine Learning; Predictive Critically; Pediatric Intensive

ABSTRAK

Pendahuluan: Banyak data yang harus dipantau dan didokumentasikan terkait kondisi kritis anak di ruangan intensif. Data tersebut berguna dalam proses tindak lanjut keperawatan. Seiring perkembangan teknologi, pendokumentasian data pasien di rumah sakit sudah menggunakan sistem elektronik dan bisa diolah secara digital untuk memberikan informasi dalam memprediksi kondisi pasien. Salah satu sistem untuk mengolah data tersebut dikenal dengan sebutan machine learning. **Metode:** Studi ini menggunakan tinjauan literatur dengan menganalisa data tentang penggunaan machine learning dalam memprediksi kondisi kritis anak secara sistematis. **Tujuan:** Memberikan gambaran dan gagasan dari hasil tinjauan jurnal tentang penggunaan machine learning dalam memprediksi kondisi kritis pada anak di ruangan intensif. **Pembahasan:** Dari hasil tinjauan 10 jurnal yang sudah dipilih, didapatkan suatu kesimpulan bahwa penggunaan machine learning dalam memberikan prediksi suatu kondisi kritis pasien lebih akurat dibandingkan metode konvensional. **Rekomendasi:** Diharapkan penggunaan machine learning bisa lebih dikembangkan di ruangan intensif anak yang membutuhkan tindakan yang cepat dan akurat.

Kata Kunci: Machine Learning; Prediksi Kondisi Kritis; Intensif Anak

PENDAHULUAN

Penyakit atau kondisi yang dapat meningkatkan angka kematian anak merupakan penyakit dan kondisi yang membutuhkan perawatan khusus di ruangan intensif. Berdasarkan penelitian Teshager, et.al tahun 2020 didapatkan angka kematian anak di ruang intensif rumah sakit Universitas Gondar Ethiopia mencapai 32,6%. Angka ini dianggap cukup tinggi sehingga dibutuhkan pemantauan dini tanda-tanda kegawatan pasien. Penelitian lain di ruangan intensif RSUD Abdul Wahab Samarinda didapatkan angka kematian anak mencapai 67,4% dari tahun 2016-2017 (Hajari, dkk, 2019). Angka kesakitan dan kematian anak ini perlu ditekankan dengan cara meningkatkan pelayanan yang terpadu pada anak dimulai dari perawatan rumah hingga perawatan pada pelayanan kesehatan primer (Puskesmas), unit gawat darurat, intermediet sampai unit rawat intensif. Perawatan intensif memerlukan ketelitian dan kecermatan dalam menilai kondisi/data pasien yang banyak serta kompleks. Proses penilaian kualitas di ruangan intensif anak harus multidisipliner. Metode yang objektif digunakan untuk membandingkan angka morbiditas dan mortalitas dengan angka prediksi untuk level keparahan penyakit pada populasi yang diperiksa (UKK ERIA, 2016).

Beberapa standar pelayanan keperawatan intensif antara lain adalah menyelamatkan nyawa, mencegah terjadinya perburukan kondisi pasien dan komplikasi melalui observasi yang ketat disertai kemampuan menginterpretasikan setiap data yang didapat dan melakukan tindak lanjut (DepKes, 2006). Banyak data tentang perkembangan kondisi pasien didokumentasikan oleh perawat. Data tersebut meliputi observasi tanda-tanda vital, skala nyeri, status neurologi, hasil laboratorium, radiologi, data cairan masuk dan keluar. Data pasien anak di ruangan intensif lebih komplisit karena juga menyangkut data antropometri, data tumbuh kembang bahkan data imunisasi anak. Data yang komplisit ini sangat membantu dalam mengetahui diagnosis penyakit,

perkembangan penyakit dan bahkan untuk kelanjutan intervensi. Sebagian besar rumah sakit di Indonesia sudah memakai sistem *Electronic Health Record (EHR)*, namun ada beberapa rumah sakit di Indonesia masih menggunakan sistem tertulis atau manual (Wulandari, Handiyani, 2019).

Perkembangan teknologi pada zaman sekarang sudah memasuki era 4.0 dimana semua sistem sudah berbentuk digital, tidak terkecuali sistem pelayanan kesehatan. Hal ini yang dikenal sebagai sistem teknologi informasi kesehatan. Teknologi informasi kesehatan didefinisikan sebagai aplikasi pemrosesan informasi yang melibatkan perangkat keras komputer dan perangkat lunak yang berhubungan dengan penyimpanan, pengambilan, pembagian dan penggunaan informasi perawatan kesehatan. Data dan pengetahuan tersebut digunakan untuk komunikasi dan pembuat keputusan (D, Brailer dalam Alotaibi, 2017).

Teknologi informasi kesehatan ini bermanfaat dalam meningkatkan dan mengubah perawatan kesehatan yang mencakup mengurangi tingkat kesalahan manusia, meningkatkan hasil klinis, memfasilitasi koordinasi perawatan, meningkatkan efisiensi tindakan dan pelacakan data dari waktu ke waktu (Alotaibi, 2017). Salah satu bentuk sistem informasi teknologi yang bisa digunakan pada sistem rumah sakit adalah *Machine Learning*. *Machine Learning* merupakan salah satu bentuk *Artificial Intelligence* yang menggunakan sistem statistik dalam mengolah data. Pemanfaatan *Machine Learning* pada sistem kesehatan dapat membantu proses pengobatan yaitu dengan memprediksi protokol pengobatan apa yang sesuai dengan kondisi pasien yang berbeda-beda (Lee SI, et.al, 2018). Selain itu, penggunaan *Machine Learning* dapat memberikan prediksi yang akurat pada data-data besar dan terstruktur dari *EHRs* (Ltifi, et.al, 2016 & Johnson, et.al, 2016). Oleh sebab itu studi tinjauan literatur ini dilakukan untuk menggambarkan penggunaan *machine*

learning dalam memprediksi kondisi kritis pada anak yang dirawat di ruangan intensif.

METODOLOGI PENELITIAN

Penelitian ini menggunakan metode tinjauan literatur, yaitu penelitian yang dilakukan dengan cara menganalisis berbagai literatur. Sumber *Database Online* yang digunakan dalam penelitian ini ada *PubMed*, *Science Direct*, *Ebsco*, *Wiley* dan *Google*

Scholar. Dari sumber tersebut dilakukan pemilihan jurnal yang berkaitan dengan 3 (tiga) kata kunci, yaitu: 1) *Machine Learning Prediction*; 2) *Critical Care*; dan 3) *Pediatric Intensive Care*. Jurnal yang didapatkan sekitar 1045, dipilih lagi sesuai rentang waktu 2015-2021 dan didapatkan 195 jurnal. Dari 195 jurnal dipilihlah 10 jurnal yang lebih relevan dengan kata kunci dan tersedia dalam bentuk *full text*.

HASIL DAN PEMBAHASAN

HASIL

Tabel 1. Rincian hasil jurnal pilihan utama untuk tinjauan literatur

Penulis / Tahun	Judul Penelitian	Nama Jurnal	Tujuan Penelitian	Metode Penelitian	Hasil Penelitian
Matam , et.al (2018).	<i>Machine learning based framework to predict cardiac arrests in a PICU.</i>	<i>Journal of clinical monitoring and computing</i>	Memprediksi kemungkinan serangan jantung pada anak dengan sakit kritis yang dirawat di ruangan intensif melalui pola denyut nadi, tekanan darah sistolik dan saturasi oksigen.	Time-series design	Hasil awal yang diperoleh dari analisis multivariat biomedis dengan time series didapatkan bahwa <i>early warning system computer based</i> lebih efisien. Selanjutnya dari 69 kejadian <i>cardiac arrest</i> yang ada, hanya 6% yang bisa diprediksi oleh tenaga kesehatan dengan metode konvensional, semetara metode <i>machine learning</i> dapat memprediksi hingga 91%-94%.
Fernandez, et.al (2018)	<i>Machine learning for outcome prediction in electroencephalography (EEG) monitored children in ICU.</i>	<i>Journal of child neurology</i>	Mengevaluasi kinerja sistem prediksi kematian pada anak kritis dengan menggunakan <i>machine Learning</i> dibandingkan	Studi deskriptif retrospektif	Evaluasi performa prediksi dengan <i>CEEG</i> dibandingkan dengan algoritma <i>machine learning</i> didapatkan bahwa hasil prediksi dengan <i>machine learning</i> lebih efektif.

dengan EEG

Ghazal, et.al (2019).	<i>Using machine learning models to predict oxygen saturation following ventilator support adjustment in critically ill children: A single-center pilot study</i>	<i>PloS one journal</i>	Menentukan apakah model prediksi <i>machine learning</i> dapat digunakan untuk memprediksi saturasi oksigen Hb lewat spirometer oksigen setelah perubahan <i>settingan ventilator</i> .	Retrospek - tif	Dari 610 pasien anak yang terpasang ventilator didapatkan hasil bahwa pada <i>machine learning model artificial neural network</i> prediktif menghasilkan algoritma dengan akurasi yang buruk dibandingkan dengan <i>machine learning model bagged complex trees</i> dengan batasan prediksi saturasi dibawah 92%
Kim, et.al (2019).	<i>A deep learning model for real-time mortality prediction in critically ill children.</i>	<i>Biomedical central journal</i>	Mengembang kan dan memvalidasi sebuah model <i>machine learning</i> " <i>Pediatric Risk of Mortality Prediction Tool (PROMPT)</i> dalam memprediksi penyebab kematian di ruangan ICU anak.	Kohort retrospek- tif observasi	Dengan menggunakan 7 tanda-tanda vital, usia pasien dan berat badan anak di ruangan intensif, <i>machine learning</i> dapat memprediksi kematian 6-60 jam sebelum hal itu terjadi. Hasil ini membuktikan bahwa mode PROMPT dengan <i>machine learning</i> ini lebih unggul dan lebih sensitif dalam memprediksi kematian anak dibandingkan dengan sistem konvensional yang menggunakan <i>Pediatric Index of Mortality</i> .
Sauter et.al (2020).	<i>Machine learning predicts prolonged acute hypoxemic respiratory failure in</i>	<i>Critical care exploration</i>	Mengidentifikasi data klinis mana yang paling baik dalam memprediksi gagal napas hipoksia akut	Kohort prospektif	Dalam penelitian ini didapatkan hasil bahwa dalam mengidentifikasi 258 anak yang mengalami hipoksia dapat diprediksi dengan baik menggunakan <i>machine</i>

	<i>pediatric severe influenza.</i>		berkepanjangan pada anak sakit kritis akibat infeksi influenza.		<i>learning</i> ke dalam data klinis sehari-hari seperti saturasi oksigen, frekuensi napas, dan denyut jantung.
Aczon, et.al (2021).	<i>Continuous prediction of mortality in the PICU: A recurrent neural network in a single-center dataset.</i>	<i>Pediatric critical care medicine journal</i>	Membuktikan model <i>neural network</i> dengan menggunakan EHR dapat menilai risiko kematian anak secara kontinyu di PICU dibandingkan dengan alat <i>Pediatric Logistic Organ Dysfunction</i> sebagai ukuran keparahan penyakit.	Kohort retrospektif	Pada 692 tes yang ditetapkan pada episode terakhir atau sama dengan 5 hari di ruangan PICU, <i>neural network</i> ini mendapatkan nilai yang lebih signifikan dibandingkan dengan pengukuran yang menggunakan <i>Pediatric Logistic Organ Dysfunction</i> ($p < 0,005$).
Bose, et.al (2021).	<i>Early prediction of multiple organ dysfunction in the PICU.</i>	<i>Frontiers in pediatric journal</i>	Mendeterminasikan model <i>machine learning</i> untuk memprediksi risiko awal berbagai disfungsi organ pada anak di ruangan PICU.	Kohort retrospektif observasi	Prediksi menggunakan 4 model <i>machine learning</i> ini memberikan hasil pemantauan pasien yang berisiko gagal organ bisa dideteksi lebih dari 22 jam sebelum terjadi kegagalan banyak organ dengan nilai prediksi positif 20,93.
Dong, et.al (2021).	<i>Machine learning model for early prediction of acute kidney injury (AKI) in</i>	<i>Biomedical central journal</i>	Mengidentifikasi pasien yang berisiko dan mencegah cedera dengan mengembangkan model	Kohort	Sebagai model prediktif untuk kasus AKI pada anak yang pertama kali, <i>machine learning</i> bisa secara akurat memprediksi hingga 48 jam sebelum AKI itu

	<i>pediatric critical care.</i>		<i>machine learning.</i>		terjadi.
Prince, et.al (2021).	<i>A machine learning classifier improves mortality prediction compared with Pediatric Logistic Organ Dysfunction Score: Model development and validation.</i>	<i>Critical care exploration journal</i>	Menentukan apakah algoritma <i>machine learning</i> lebih baik dalam memprediksi tingkat kematian dari pada <i>Pediatric Logistic Organ Dysfunction-2 Score (PLOD 2)</i> .	Retrospek -tif	Hasil algoritma secara random terlihat model <i>random forest machine learning</i> menunjukkan kalibrasi yang lebih baik dibandingkan penggunaan <i>PLOD 2 score</i> dalam memprediksi kematian pada anak.
Comer etto et.al (2021).	<i>Predicting hemodynamic failure development in PICU using machine learning techniques.</i>	<i>MDPI journal</i>	Mengidentifikasi prediktor untuk mendeteksi kegagalan tanda-tanda vital selama anak dirawat di PICU menggunakan <i>machine learning techniques</i> .	Kohort	Dari total sampel 29.494 subjek, terdapat 399 yang mengalami gagal hemodinamik selama masa percobaan. Usia rata-rata adalah 2 tahun dengan jenis kelamin paling banyak laki-laki. Dari berbagai predictor <i>machine learning</i> didapatkan model <i>XGB</i> lebih unggul dalam memprediksi kegagalan hemodinamik dengan ukuran rata-rata 0,78 (IQR 0,77-0,793)

PEMBAHASAN

Data dan informasi yang telah dikumpulkan dari anak dengan kondisi kritis yang dirawat di ruangan intensif jumlahnya cukup besar. Data tersebut bisa diolah dan dianalisis menjadi suatu informasi. Selain itu, bisa juga diambil sebagai bahan kajian untuk memprediksi suatu keadaan dimasa yang akan datang. Kemampuan perawat dalam mengambil dan mengolah data sangat terbatas. Hal ini terkait dengan jumlah dan variasi data yang

besar sehingga penggunaan *machine learning* diharapkan mampu mengolah jumlah data tersebut. (Shulman, 2008 dalam Williams, Jon, et.al, 2018).

Machine learning memiliki manfaat dalam meningkatkan kualitas layanan kesehatan karena mampu menyajikan diagnosis hingga memprediksi penyakit (Rayan, Alfonse, & Salem, 2019). Beberapa penerapan *machine learning* pada area keperawatan anak kritis dalam

memprediksi berbagai kondisi pasien menunjukkan hasil yang akurat. Penelitian Matam tahun 2018 memprediksi kejadian henti jantung pada anak menunjukkan bahwa penilaian yang dilakukan oleh tenaga kesehatan dengan metode konvensional hanya mencapai 6% dibandingkan dengan *machine learning* bisa mencapai 91%. Penelitian ini juga membandingkan kecepatan dan keakuratan antara *machine learning* dengan skor *Pediatric Early Warning System (PEWS)*. Hasilnya metode *machine learning* lebih unggul 7% dibandingkan *PEWS*. *Pediatric Early Warning System* merupakan sistem yang biasa digunakan untuk mendeteksi dini kondisi anak sebelum beberapa jam terjadi perburukan (Dewi, 2016).

Penggunaan *machine learning* dipakai juga untuk memprediksi kejadian gagal nafas pada anak dengan hipoksemia akut dan menunjukkan hasil yang signifikan. Sauther, et.al tahun 2020 mengatakan bahwa gagal nafas akibat hipoksemia akut pada anak yang berkepanjangan selama 1 minggu sangat berhubungan dengan tingkat keparahan pernapasan diawal rawatan dan berevolusi pada hari ke-2. Hal ini lebih lanjut dikaitkan dengan angka kematian yang jauh lebih tinggi. Oleh sebab itu dengan model prediksi *machine learning* ini dapat membantu dalam menargetkan kelompok yang paling parah pada 24 jam pertama setelah pasien masuk rumah sakit. Dengan demikian, tenaga kesehatan dapat dipandu dalam mengantisipasi kejadian lebih lanjut. Penelitian mengenai prediksi gagal nafas ini sejalan dengan yang dilakukan oleh David tahun 2020. David menggunakan model *machine learning* dalam memprediksi gagal nafas pada pasien Covid-19. Hasil yang diperoleh bahwa *machine learning* mampu memprediksi kejadian gagal nafas pada

PLOD (*Pediatric Logistic Organ Dysfunction*), sementara Prince, et.al pada tahun 2021 membandingkan model *random forest* pada *machine learning* dengan PLOD-2 score. Semua hasil penelitian tersebut membuktikan bahwa alat ukur

pasien Covid-19 hingga 84% lebih akurat.

Kondisi-kondisi lain yang bisa diprediksi dengan penggunaan model *machine learning* pada anak kritis seperti kegagalan hemodinamik dan kejadian *Acute Kidney Injury*. Kedua kasus ini sama-sama menunjukkan hasil yang akurat. Hanya saja dalam pelaksanaannya masih dibutuhkan penelitian lebih lanjut untuk meningkatkan validasi sehingga dapat digunakan dalam praktik klinis yang sesungguhnya (Comeretto, et.al, & Dong, et.al, 2021). Berbeda dengan penelitian Ghazal, et.al (2019) yang menyatakan bahwa penggunaan model *machine learning predictive* yang biasa tidak memberikan algoritma akurasi yang baik dalam memprediksi kadar saturasi oksigen pada anak yang terpasang ventilator, tetapi pada model *machine learning bagged complex trees* mampu menunjukkan hasil yang baik. Oleh sebab itu perlu peninjauan ulang tentang algoritma *machine learning* dalam mengekstraksikan pengetahuan dari data yang ada dengan sistem ventilator mekanis.

Berikut beberapa hasil penelitian lain yang membandingkan penggunaan alat tertentu dengan penggunaan *machine learning* dalam memprediksi kematian anak di ruangan intensif. Fernandez (2019), melakukan perbandingan *machine learning* dengan *Continuous Electroencephalography (CEEG)* dalam memprediksi kematian pada anak di ruangan intensif. Kim (2019), membandingkan antara *Machine Learning* metode PROMPT (*Pediatric Risk of Mortality Prediction Tool*) dengan *Pediatric Index of Mortality (PIM)*. Aczon, et.al (2021) juga melakukan perbandingan prediksi kematian anak antara *machine learning* model *neural network* dengan

yang dipakai untuk memprediksi kematian anak kritis tidak lebih baik dibandingkan dengan penggunaan *machine learning*. Sehingga dapat disimpulkan bahwa *machine learning* merupakan alat prediksi yang paling akurat dan cepat dalam

memberikan hasil pada pengolahan data dengan variasi dan jumlah yang besar dibandingkan model prediksi konvensional (Schneider, Neil & Wilmes, Arthur L, 2014).

Penggunaan *machine learning* dapat meningkatkan keakuratan dalam memprediksi suatu kondisi, tapi jika sumber data yang diolah dari suatu rumah sakit tersebut tidak lengkap atau tidak valid, maka hasil yang diberikan juga akan terbatas (Chen, et.al, 2017). Oleh sebab itu, penggunaan *machine learning* pada keadaan yang sesungguhnya memerlukan data yang sudah divalidasi. Kelemahan dari beberapa penelitian mengenai penggunaan *machine learning* disebabkan karena data yang diambil merupakan data yang sudah lalu dan belum divalidasi, serta ada yang tidak melewati proses *training*. Penggunaan *machine learning* dalam melakukan prediksi harus melewati beberapa tahapan untuk mendapatkan hasil yang akurat (Santoso, dkk, 2020).

SIMPULAN

Penggunaan *machine learning* sebagai sistem prediksi kondisi kritis pada anak yang dirawat di ruangan intensif menunjukkan hasil yang lebih akurat namun dalam penerapannya pada kondisi yang nyata dan aktual masih perlu dilakukan validasi data dan penelitian lebih

lanjut. Hal ini disebabkan karena data yang dianalisis dalam penelitian-penelitian tersebut diambil dari kejadian yang telah lalu. Hampir semua penelitian dari tinjauan literatur ini menggunakan metode retrospektif. Penggunaan *machine learning* dalam memprediksi kondisi kesehatan anak di ruang intensif sangat berguna dan membantu pekerjaan dokter, perawat atau tenaga kesehatan lainnya. Pada saat ini hasil prediksi *machine learning* terbatas dari data pasien yang telah lalu. Meski demikian, hasil tersebut tetap berguna dalam mengevaluasi tindakan yang telah diberikan. Selain itu, hasil prediksi dari data yang lalu tersebut bisa menjadi dasar untuk meningkatkan rencana tindakan keperawatan ketika menghadapi kasus yang sama di kemudian hari. Oleh sebab itu diharapkan pengembangan dalam penggunaan *machine learning* di ruangan intensif anak agar membantu proses intervensi dimasa yang akan datang.

UCAPAN TERIMA KASIH

Terimakasih kepada Bapak Ns. La Ode Abdul Rahman, S.Kep., MBA selaku fasilitator dalam mata kuliah Sistem Informasi Manajemen, Program Studi Magister Keperawatan, Peminatan Anak Universitas Indonesia tahun 2021 dalam penulisan manuskrip ini.

DAFTAR PUSTAKA

Alotaibi, Y. K., & Federico, F. (2017). The impact of health information technology on patient safety. *Saudi Medical Journal*, Vol 38(12), p 11731180. <https://doi.org/10.15537/smj.2017.12.20631>.

Aczon, Melissa D. PhD^{1,2}; Ledbetter, David R. BS^{1,2}; Laksana, Eugene BS^{1,2}; Ho, Long V. BS^{1,2}; Wetzell, Randall C. MB BS, FAAP, FCCM, MRCP, LRCS, MSB¹⁻³. (2019). Continuous

prediction of mortality in the PICU: A recurrent Neural Network Model in a Single-Center Dataset*. *Pediatric Critical Care Medicine: Volume 22 - Issue 6 - p 519-529*. <https://doi.org/10.1097/PCC.0000000000002682>.

Bose, S. N., Greenstein, J. L., Fackler, J. C., Sarma, S. V., Winslow, R. L., & Bembea, M. M. (2021). Early Prediction of Multiple Organ

- Dysfunction in the Pediatric Intensive Care Unit. *Frontiers in pediatrics*, 9, 711104. <https://doi.org/10.3389/fped.2021.711104>.
- Chen, J. H., & Asch, S. M. (2017). Machine Learning and Prediction in Medicine - Beyond the Peak of Inflated Expectations. *The New England journal of medicine*, 376(26), 2507–2509. <https://doi.org/10.1056/NEJMp1702071>.
- Comoretto, R. I., Azzolina, D., Amigoni, A., Stoppa, G., Todino, F., Wolfler, A., Gregori, D., & On Behalf of The TIPNet Study Group (2021). Predicting Hemodynamic Failure Development in PICU using Machine Learning Techniques. *Diagnostics (Basel, Switzerland)*, 11(7), 1299. <https://doi.org/10.3390/diagnostics11071299>.
- Departemen Kesehatan. (2006). Standar Pelayanan Keperawatan di ICU. Direktorat Keperawatan dan Keteknisian Medis Direktorat Jenderal Pelayanan Medik DepKes RI.
- Dewi, Rismala. (2016). *Pediatric Early Warning System Score: Bagaimana Langkah kita selanjutnya*. *Jurnal Sari Pediatri Vol 18(1)*, hal 68-73. <https://dx.doi.org/10.14238/sp18.1.2016.68.73>.
- Dong, J., Feng, T., Thapa-Chhetry, B., Cho, B. G., Shum, T., Inwald, D. P., Newth, C., & Vaidya, V. U. (2021). Machine learning model for early prediction of acute kidney injury (AKI) in pediatric critical care. *Critical care (London, England)*, 25(1), 288. <https://doi.org/10.1186/s13054-021-03724-0>.
- Ferrari D, Milic J, Tonelli R, Ghinelli F, Meschiari M, Volpi S, et al. (2020) Machine learning in predicting respiratory failure in patients with COVID-19 pneumonia— Challenges, strengths, and opportunities in a global health emergency. *PLoS ONE 15(11): e0239172*. <https://doi.org/10.1371/journal.pone.0239172>
- Ghazal, S., Sauthier, M., Brossier, D., Bouachir, W., Jouvret, P. A., & Noumeir, R. (2019). Using machine learning models to predict oxygen saturation following ventilator support adjustment in critically ill children: A single center pilot study. *PloS one*, 14(2), e0198921. <https://doi.org/10.1371/journal.pone.0198921>.
- Hajari, Siti., Sawitri, Endang., Mhy, Annisa., Nugroho, Harry. (2017) Gambaran mortalitas pasien di ruang PICU RSUD Abdul Wahab Sjahranie Samarinda periode 2016-2017. *Jurnal Mutiara Mahakam Vol 7(1)*, hal 41-57.
- Kim, S.Y., Kim, S., Cho, J. *et al.* A deep learning model for real-time mortality prediction in critically ill children. (2019). *Crit Care* 23, 279. <https://doi.org/10.1186/s13054-019-2561-z>.
- Johnson, A. E., Ghassemi, M. M., Nemati, S., Niehaus, K. E., Clifton, D. A., & Clifford, G. D. (2016). Machine Learning and decision support in Critical Care. *Proceedings of the IEEE. Institute of Electrical and Electronics Engineers*, 104(2), 444–466. <https://doi.org/10.1109/JPROC.2015.2501978>.
- Lee, S. I., Celik, S., Logsdon, B. A., Lundberg, S. M., Martins, T. J., Oehler, V. G., Estey, E. H., Miller, C. P., Chien, S., Dai, J., Saxena, A., Blau, C. A., & Becker, P. S. (2018). A machine learning approach to integrate big data for precision medicine in acute myeloid leukemia. *Nature communications*, 9(1), 42.

- <https://doi.org/10.1038/s41467-017-02465-5>.
- Ltifi H., Ayed M.B. (2016). Visual intelligent decision support systems in the Medical Field: Design and evaluation. In: Holzinger A. (eds) Machine Learning for health informatics. *Lecture Notes in Computer Science*, vol 9605. Springer, Cham. https://doi.org/10.1007/978-3-319-50478-0_12.
- Matam, B. R., Duncan, H., & Lowe, D. (2019). Machine learning based framework to predict cardiac arrests in a pediatric intensive care unit: Prediction of cardiac arrests. *Journal of clinical monitoring and computing*, 33(4), 713–724. <https://doi.org/10.1007/s10877-018-0198-0>.
- Neil, SchneiderWilmes, Arthur I. (2014) Predicting future health care expenses with machine learning. *Milliman White Paper* diakses dari www.milliman.com.
- Prince, R. D., Akhondi-Asl, A., Mehta, N. M., & Geva, A. (2021). A Machine Learning Classifier Improves Mortality Prediction Compared with Pediatric Logistic Organ Dysfunction-2 Score: Model Development and Validation. *Critical care explorations*, 3(5), e0426. <https://doi.org/10.1097/CCE.0000000000000426>.
- Rayan, Zeina & Alfonse, Marco & M.Salem, Abdel-Badeeh. (2019). Machine Learning Approaches in Smart Health. *Procedia Computer Science*. 154. 361-368. <https://doi.org/10.1016/j.procs.2019.06.052>.
- Sánchez Fernández, I., Sansevere, A. J., Gaínza-Lein, M., Kapur, K., & Loddenkemper, (2018). Machine Learning for outcome prediction in Electroencephalograph (EEG)-Monitored children in the Intensive Care Unit. *Journal of child neurology*, 33(8), 546–553. <https://doi.org/10.1177/0883073818773230>.
- Santoso, Resky Ramadhani. (2020) Implementasi metode *machine learning* menggunakan algoritma *evolving artificial neural network* pada kasus prediksi diagnosis Diabetes Melitus. Universitas Pendidikan Indonesia, respiratory. perpustakaan.upi.edu.
- Sauthier, M. S., Jouvett, P. A., Newhams, M. M., & Randolph, A. G. (2020). Machine Learning predicts prolonged acute hypoxemic respiratory failure in Pediatric severe Influenza. *Critical care explorations*, 2(8), e0175. <https://doi.org/10.1097/CCE.0000000000000175>.
- Teshager, N. W., Amare, A. T., & Tamirat, K. S. (2020). Incidence and predictors of mortality among children admitted to the pediatric intensive care unit at the University of Gondar comprehensive specialized hospital, northwest Ethiopia: a prospective observational cohort study. *BMJ Open*, 10(101), e056746. <https://doi.org/10.1136/bmjopen-2019-036746>.
- UKK ERIA. (2016). Buku Panduan Pelayanan Emergensi Rawat Intermediet dan Rawat Intensive Anak. Jakarta: Badan Penerbit Ikatan Dokter Anak Indonesia.
- Williams, J. B., Ghosh, D., & Wetzel, R. C. (2018). Applying Machine Learning to Pediatric Critical Care Data. *Pediatric critical care medicine: a journal of the Society of Critical Care Medicine and the World Federation of Pediatric Intensive and Critical Care Societies*, 19(7), 599–608. <https://doi.org/10.1097/PCC.0000000000001567>.

Wulandari, Diah Fitri & Handiyani, Hanny. (2007). Pengembangan dokumentasi keperawatan berbasis elektronik di RS X Kota Depok

dengan menggunakan teori perubahan Lewins. *Jurnal Keperawatan Global, Vol 4 (1), hlm 1-73.*