

Penerapan machine learning dalam meningkatkan produktivitas di industri manufaktur: Tinjauan literatur

(Implementation of machine learning to increase productivity in the manufacturing industry: A literature review)

Yulio Agefa Purmala¹

¹Departemen Equipment Management, PT. Victory Chingluh Indonesia, Tangerang

Corresponding author: yagefa@gmail.com

Received 15 June 2021, 07 July 2021, Accepted 19 July 2021

Abstrak. Industri 4.0 saat ini telah berkembang cukup pesat, salah satu teknologi yang saat ini sangat populer diterapkan di dalam industri adalah teknologi kecerdasan buatan atau *artificial intelligence*, di mana suatu peristiwa dapat didiagnosa dan diprediksi secara lebih cepat dan akurat. Salah satu cabang dari *artificial intelligence* yang dapat melakukan hal tersebut adalah *machine learning*, bahkan penerapannya kini dapat ditemukan dalam kegiatan sehari-hari. Dalam industri manufaktur, penerapan *machine learning* salah satunya adalah untuk meningkatkan produktivitas melalui hasil analisa dan prediksi yang diberikan berdasarkan pengalaman yang didapat. Penelitian ini menggunakan metode tinjauan literatur secara sistematis, dimana sejumlah artikel dikumpulkan dari beberapa *database* jurnal seperti Elsevier, IEE, Springer, Taylor & Francis dan ACM, dengan periode penerbitan artikel tahun 2015 - 2020. Sebanyak 100 artikel berhasil dihimpun, kemudian divalidasi kembali kesesuaiannya berdasarkan tujuan dan sasaran utama penelitian. Didapat 36 artikel yang tervalidasi dan digunakan sebagai referensi untuk dilakukan peninjauan dan analisa yang lebih mendalam terhadap batasannya, sehingga didapatkan celah untuk dilakukan penelitian lebih lanjut. Dalam penelitian tinjauan literatur ini bisa dilihat bahwa penerapannya sangat membantu dalam pengambilan suatu keputusan dalam peningkatan kualitas, efisiensi, dan performa perusahaan dalam industri manufaktur. Algoritma yang paling populer digunakan dalam penelitian ini diantaranya *random forest*, *support vector machine*, *neural network*, *linear regression* dan *k-nearest neighbour*. Akhirnya pada penelitian ini ditemukan bahwa penerapan *machine learning* dalam mendiagnosis atau memprediksi suatu kejadian disarankan dengan melakukan pemodelan lebih dari satu algoritma agar dapat mencari dan menentukan algoritma mana yang paling akurat dan sesuai untuk diterapkan pada fenomena yang terjadi.

Kata kunci: *machine learning*, kecerdasan buatan, industri manufaktur, produktivitas, tinjauan literatur.

Abstract. Industry 4.0 is currently developing quite rapidly, one of the technologies that is currently very popular in the industry is artificial intelligence, where an event can be diagnosed and predicted more quickly and accurately. One of the branches of artificial intelligence that can do this is Machine Learning, and its application can now be found in daily activities. In the manufacturing industry, the application of Machine Learning is one of them is to increase productivity through the results of analysis and predictions given based on the experience gained. This study uses a systematic literature review method, in which several articles were collected from several journal databases such as Elsevier, IEE, Springer, Taylor & Francis and ACM, with the publication period of the articles from 2015 to 2020. A total of 100 articles were collected, then re-validated. suitability based on the main goals and objectives of the research. There were 36 articles that were validated and used as a reference for a more in-depth review and analysis of their boundaries, so that there was a gap for further research. In this literature review study, its application is very helpful in making decisions in improving the quality, efficiency, and performance of companies in the manufacturing industry. The most popular algorithms used in this study include random forest, support vector machine, neural network, linear regression, and k-nearest neighbor. Finally, in this study it was found that the application of Machine Learning in diagnosing or predicting an event is suggested by modeling more than one algorithm to find and determine which algorithm is the most accurate and suitable to be applied to the phenomenon that occurs.

Keywords: *machine learning, artificial intelligence, manufacturing industry, productivity, literature review.*

1 Pendahuluan

Perkembangan teknologi industri 4.0 saat ini cakupannya telah sangat luas (Frank et al., 2019), mulai dari teknologi otomatisasi, *IoT*, *cloud computing*, sistem terintegrasi, *3D printing*, *big data*, hingga teknologi yang saat ini tengah menjadi perbincangan hangat yakni kecerdasan tiruan atau *artificial intelligence* (Lu et al., 2017) (J. Lee et al., 2018). Dengan adanya teknologi ini diharapkan dapat meningkatkan produktivitas terhadap pekerjaan atau aktivitas yang dilakukan.


Salah satu teknologi yang populer saat ini yaitu *artificial intelligence*, di mana suatu peristiwa yang akan terjadi dapat di diagnosa atau diprediksi secara akurat (Agrawal et al., 2019). Menurut (Fahle et al., 2020), salah satu cabang dari *artificial intelligence* yang paling banyak digunakan adalah *machine learning*, yakni suatu metode yang dapat membuat komputer melakukan pembelajaran berdasarkan pengalamannya tanpa perlu melakukan suatu pemrograman secara eksplisit. Dalam penerapannya saat ini telah banyak digunakan tidak hanya dalam industri saja, namun kini sudah merambah dalam kehidupan sehari-hari seperti pencarian dalam internet, rekomendasi produk dalam *market place*, iklan di internet hingga diagnosis medis (Ramamurthy & Roy, 2018) (Alemdar et al., 2015).

Penerapan *machine learning* dalam industri, terutama industri manufaktur banyak diterapkan guna meningkatkan produktivitas dalam proses bisnisnya (Brito et al., 2020) (Ruiz et al., 2020). Data-data yang selama ini diolah secara manual akan di gantikan dengan algoritma dalam *machine learning*, sehingga di harapkan suatu keputusan penting dapat dilakukan secara cepat dan akurat (Ağbulut et al., 2020). Penerapan *machine learning* pada manufaktur untuk meningkatkan produktivitas diantara-Nya digunakan untuk melakukan inspeksi dalam pengendalian kualitas untuk produk yang lebih baik (Brito et al., 2020)(Hürkamp et al., 2020)(Caggiano et al., 2019), melakukan prediksi suatu produk dan proses (Wu et al., 2017) dan melakukan efisiensi proses (Kim et al., 2019).

Berdasarkan sifat pembelajarannya terdapat 3 jenis *machine learning* yang dapat di terapkan sesuai dengan kondisi dan data yang ada, yakni *supervised learning*, *unsupervised learning* dan *reinforcement learning* (Dey, 2016). Setiap jenis memiliki algoritma yang berbeda-beda, sehingga perlunya melakukan perbandingan dan evaluasi terhadap beberapa algoritma demi mendapatkan hasil yang paling akurat (Wessel et al., 2018). Berdasarkan hal tersebut, dalam penelitian ini akan dikaji lebih mendalam terkait algoritma yang menjadi faktor sukses dalam keberhasilan penerapannya guna meningkatkan produktivitas dalam industri manufaktur.

2 Metoda

Metodologi yang digunakan dalam penelitian ini adalah analisa tinjauan literatur secara sistematis, karena lebih ringkas, padat dan jelas dalam menganalisis isu terkait penelitian sebelumnya. Penulis dapat menyimpulkan bahwa memang tinjauan literatur sangat penting dan perlu dipertimbangkan agar dapat melihat celah dan potensi untuk melakukan penelitian lebih lanjut. Oleh karena itu tujuan dari penelitian ini adalah untuk menyajikan gambaran yang komprehensif dari beberapa penelitian dari jurnal terkemuka terkait *machine learning* periode 2015 – 2020, untuk dapat mengeksplorasi lebih jauh lagi terkait penerapan *machine learning* di industri manufaktur dan eksplorasi lebih mendalam pada keterbatasan setiap penelitian terdahulu. Terdapat 10 poin utama dalam pendekatan tinjauan literatur secara sistematis: (1) Analisa dan identifikasi tujuan dan sasaran, (2) menentukan protokol penentuan kriteria, (3) Menetapkan kriteria yang relevan, (4) Pencarian literatur di beberapa *database* jurnal, (5) Pemilahan artikel berdasarkan topik, (6) Evaluasi kualitas dari artikel yang diperoleh, (7) Pengumpulan data yang terkait, (8) Analisa, (9) Pembuatan Laporan, (10) Publikasi penelitian. Penelitian ini dilakukan dengan menganalisis Judul dan abstrak untuk menghindari pemborosan waktu dan sumber daya, sehingga persyaratan penyertaan dan pengecualian dilakukan untuk membuatnya dapat dipahami oleh publik bahwa publikasi yang sejenis mungkin tidak masuk ke dalam kriteria, dapat dilihat pada Gambar 1.



Gambar 1 Kerangka berpikir.

Penelitian ini ditulis berdasarkan 50 artikel jurnal dari beberapa *database* seperti Elsevier, IEE, Springer, Taylor & Francis dan ACM. Agar penelitian ini tetap terkini dan spesifik maka dari beberapa jurnal yang berhasil dikumpulkan tidak dimasukkan dalam penelitian ini berdasarkan kriteria yang telah ditentukan, dapat dilihat pada Tabel 1.

Tabel 1 Kriteria penelitian

Termasuk	Tidak Termasuk
Publikasi artikel tahun 2015 - 2020	Publikasi artikel sebelum tahun 2015
Jurnal akademis	Buku, Pencarian Online
Artikel studi kasus	Artikel tinjauan literatur
Industri Manufaktur	Industri selain manufaktur

Sumber: Data Olah

3 Hasil dan Pembahasan

Seperti yang terlihat pada Tabel 2 beberapa masalah utama telah dijabarkan setelah melakukan analisa yang cukup mendalam terkait perbandingan dari literatur yang ada. Terdapat 36 artikel dalam berbagai perspektif untuk membantu peneliti, akademisi dan praktisi lebih dalam memahami dan melihat lebih dekat pada penerapan *machine learning* di industri manufaktur. Penulis memiliki klasifikasi berbagai penelitian berdasarkan tujuan dan hasil pencapaian dalam penerapan *machine learning*.

Tabel 2 Artikel jurnal terkait *machine learning* di industri manufaktur

No.	Penulis	Tujuan	Hasil	Algoritma
1	(Brito et al., 2020)	Nol cacat dan kualitas tinggi	Inspeksi cerdas untuk sistem kendali kualitas	NN
2	(Filz et al., 2020)	Peningkatan produk	Kendali variasi produk	DBSCAN
3	(Hürkamp et al., 2020)	Investigasi penggabungan proses	Akurasi kualitas kekuatan waktu ikatan (<i>bonding</i>)	RF, PR, GB, DT, AB
4	(Oberlé et al., 2020)	Prediksi masa pakai alat potong	Penggunaan alat bersifat acak sulit untuk prediksi secara akurat	RF
5	(Romeo et al., 2020)	Prediksi dan estimasi spesifikasi mesin	Mendukung pemilihan desain	DT, K-NN
6	(Ruiz et al., 2020)	Prediksi kekuatan baja	Variabel kimia memberi pengaruh terhadap kekuatan besi	LR, K-NN, CART, RF, GB, AB, ANN
7	(Wang et al., 2020)	Meningkatkan daya tanggap dan keandalan layanan komputasi	Prediksi penggunaan <i>bandwidth</i> unggahan dan unduhan	LR, RF
8	(Caggiano et al., 2019)	Identifikasi cacat material	Deteksi cacat secara Online	NN
9	(Carvajal Soto et al., 2019)	Deteksi kegagalan pemasangan perangkat	Menganalisis berbagai aspek	NN, RF, GB
10	(Cavalcante et al., 2019)	Meningkatkan minat dalam pemilihan pemasok yang tangguh	Desain strategi mengurangi risiko dalam manajemen gangguan rantai pasokan	RF, LR, K-NN

Tabel 2 Lanjutan

No.	Penulis	Tujuan	Hasil	Algoritma
11	(Diren et al., 2019)	Kontrol kualitas dalam proses manufaktur multivariat	Menentukan akar masalah dalam pengendalian kualitas.	NN, AB
12	(Kim et al., 2019)	Mempertahankan stok untuk menghemat biaya pemeliharaan.	Mengevaluasi persediaan yang diharapkan	ARIMA, LSTM
13	(S. Lee et al., 2019)	untuk memahami dan memprediksi formasi kolam lelehan berbasis fisika	Sebagai dasar untuk kontrol kolam lelehan dan optimalisasi proses.	BR, KR, LR, NN, RF, SVM
14	(Li, Liu, et al., 2019)	Pemantauan keausan alat secara <i>real-time</i>	mengklasifikasikan kondisi keausan alat dengan akurasi tinggi.	CART, RF, K-NN, SVM
15	(Li, Zhang, et al., 2019)	Meningkatkan integritas permukaan yang diproduksi secara aditif,	Memprediksi kekasaran permukaan komponen 3D dengan akurasi tinggi	RF, AB, CART, SVM, RVFL
16	(Lolli et al., 2019)	Klasifikasi inventaris Multi-kriteria	Sistem persediaan yang diadopsi cocok untuk permintaan yang berselang	SVM, DNN
17	(C. Morariu et al., 2019)	Pengumpulan konsumsi energi di berbagai lapisan	Peramalan akurat dari pola konsumsi energi	RNN, LSTM
18	(Murphy et al., 2019)	Estimasi waktu aliran pesanan di bengkel kerja yang dinamis	Memprediksi kapan pesanan bisa diselesaikan	MAL, RMSL, FR
19	(Nkonyana et al., 2019)	Mengurangi jumlah kesalahan	Diagnosis kesalahan yang dapat membantu pengambilan keputusan	RF, ANN, SVM
20	(Peres et al., 2019)	Memprediksi cacat secara dimensi	Membantu mengurangi biaya sekrup dan perbaikan	XGB, RF
21	(Zeng et al., 2019)	Analisis keamanan manufaktur	Performa yang lebih baik dari perbandingan serangan	RF
22	(Candanedo et al., 2018)	mendeteksi pola dalam data yang dianalisis	Uji kinerja peralatan	LR, RF
23	(Escobar & Morales-Menendez, 2018)	mendeteksi kejadian langka yang berkualitas.	100% cacat dapat dideteksi secara efektif	LR
24	(Moldovan et al., 2018)	mengklasifikasikan produk yang dihasilkan oleh proses manufaktur	penggunaan MPC untuk mengklasifikasikan produk	ANN, SVM, NB, DT, K-NN, LR
25	(O. Morariu et al., 2018)	sistem manufaktur skala besar	memprediksi berbagai skenario sebelum degradasi layanan terjadi	LR
26	(Paolanti et al., 2018)	Perawatan prediktif	memprediksi kondisi mesin yang berbeda dengan akurasi tinggi	RF
27	(Syafudin et al., 2018)	memberikan pemantauan proses produksi yang efisien	mendukung manajemen dengan meningkatkan pengambilan keputusan kinerja tergantung pada panjang data pelatihan.	NB, LR, MP, RF, DBSCAN
28	(Bai et al., 2017)	Prediksi akurat proses manufaktur	saran untuk integrasi dalam sistem simulasi	FNN, SVM, DRBM, SAN
29	(Bergmann et al., 2017)	mengurangi waktu dan tenaga untuk membuat model simulasi		K-NN, NBC, SVM, CART, ANN
30	(Ko et al., 2017)	memperkirakan kualitas produk dengan cara yang diawasi.	mendeteksi mesin yang rusak dengan probabilitas tinggi	<i>Anomaly Detection</i>
31	(Moldovan et al., 2017)	mengelola proses produksi	menunjukkan nilai presisi yang lebih baik saat fitur dipilih	GBT, RF, LR
32	(Wu et al., 2017)	memperkenalkan metode prognosis berbasis <i>random forest</i> (RF) untuk prediksi keausan pahat	RF dapat menghasilkan prediksi yang lebih akurat daripada JST TBS dengan satu lapisan tersembunyi dan SVR	RF, SVM, ANN
33	(J. H. Han & Chi, 2016)	menyelesaikan tugas sederhana yang memakan waktu dan biaya tinggi	memprediksi offset kompensasi keausan alat CNC	SVM

Tabel 2 Lanjutan

No.	Penulis	Tujuan	Hasil	Algoritma
34	(Park et al., 2016)	inspeksi visual otomatis terhadap kotoran, goresan, gerinda, dan keausan pada bagian permukaan	menghemat waktu dan biaya dan menunjukkan kinerja yang lebih tinggi	CNN
35	(J.-H. Han et al., 2015)	menyajikan tren terkini dalam menerapkan <i>machine learning</i>	kerangka kerja umum rekomendasi parameter kompensasi keausan alat sistem keputusan	LR, SVM, ANN
36	(Susto et al., 2015)	Perawatan prediktif	pemeliharaan berbasis untuk meminimalkan biaya	SVM, KNN

Singkatan: SVM = Support Vector Machine; LR = Linear Regression; NB = Naïve Bayes; RF = Random Forest; k-NN = k-Nearest Neighbour; ANN = Artificial Neural Network; GB = Gradient Boosting; BR = Bayesian Ridge; KR = Kernel Ridge; CART = Classification And Regression Trees; RVFL = Random Vector Functional Link; DT = Decision Trees; MP = Multilayer Perception; NN = Neural Network; DBSCAN = Densitybased Spatial Clustering of Applications with Noise; PR = Polynomial Regression; XGB = XG Boost; AB = Ada Boost; ARIMA = Autoregressive model Moving Average; MAL = Mean Absolute Lateness; RMSL = Root Mean Squared Lateness; FR = Fill Rate; FNN = Feed Forward Neural Network; DRBM = Deep Restricted Boltzmann Machine; SAN = Stack Autoencoder Network

Berdasarkan beberapa artikel yang berhasil dikumpulkan dapat dilihat pada Tabel 2, bahwa *machine learning* sangat bermanfaat dalam beberapa aspek peningkatan produktivitas melalui diagnosis dan prediksi dalam membantu pengambilan suatu keputusan secara akurat, diantaranya yakni prediksi untuk meningkatkan akurasi inspeksi terhadap kualitas dengan mendeteksi suatu mesin atau produk dengan probabilitas tinggi menggunakan algoritma *neural network* (Brito et al., 2020) (Ko et al., 2017) (Park et al., 2016) (Carvajal Soto et al., 2019) (Diren et al., 2019) (Peres et al., 2019) (Escobar & Morales-Menendez, 2018), meningkatkan pengembangan produk untuk dapat mengendalikan variasi terhadap produk dengan menggunakan algoritma DBSCAN (Filz et al., 2020) (Ruiz et al., 2020) (Li, Zhang, et al., 2019), meningkatkan efisiensi dalam proses produksi seperti kontrol stok untuk mengevaluasi persediaan yang diharapkan sehingga menghemat biaya pemeliharaan dengan menggunakan algoritma *autoregressive integrated moving average* (Kim et al., 2019) (Murphy et al., 2019) (Syafudin et al., 2018) (Bergmann et al., 2017) (J. H. Han & Chi, 2016), memaksimalkan dalam melaksanakan kegiatan perawatan preventif dan analisa kondisi mesin seperti dengan menggabungkan beberapa algoritma seperti CART, RF, K-NN dan SVM sehingga dapat mengklasifikasikan kondisi keausan alat dengan akurasi tinggi. (Li, Liu, et al., 2019) (Paolanti et al., 2018) (Susto et al., 2015) dan yang terakhir adalah sebagai suatu alat pendukung dalam pengambilan suatu keputusan (Cavalcante et al., 2019) (J.-H. Han et al., 2015). Dapat dilihat pada **Gambar 2** dimana implementasi *supervised learning* untuk meningkatkan akurasi terhadap kualitas demi terciptanya produktivitas yang baik menjadi angka tertinggi dari beberapa penelitian yang dilakukan.

**Gambar 2** Fokus penelitian dan potensi area

Hasil analisa dan prediksi dalam menggunakan *machine learning* yang baik adalah yang menerapkan pemodelan menggunakan 2 algoritma yang berbeda, karena hal ini bertujuan untuk mendapatkan model yang baik yang dapat memberikan akurasi prediksi yang sangat baik. Dari beberapa algoritma yang digunakan pada penelitian terdahulu maka ada beberapa algoritma yang secara umum digunakan dalam mendiagnosis dan memprediksi suatu fenomena berdasarkan data yang telah di dapat dan di olah dengan baik, diantaranya yakni *random forest*, *support vector*

machine, *neural network*, *decision tree*, *k-nearest neighbour*, dan *linear regression*. Pada dasarnya algoritma yang digunakan telah ditentukan berdasarkan sifat dari data yang dimiliki hal ini dikarenakan penerapan algoritma disesuaikan dengan fungsi dan sifat data yang digunakan. penerapan *machine learning* sangat membantu dalam meningkatkan produktivitas di industri manufaktur, banyak hal yang bisa dilakukan seperti akurasi dalam kualitas, efisiensi, peningkatan produk, perawatan dan pastinya sebagai alat manajemen dalam pengambilan keputusan-keputusan kritis bagi perusahaan.

4 Kesimpulan

Dari hasil data dan analisa yang telah dilakukan maka dapat ditemukan beberapa poin yang dapat disimpulkan, diantaranya; Berdasarkan data yang berhasil dikumpulkan bahwa metode *supervised learning* menjadi salah satu metode yang paling banyak di implementasikan karena biasanya peneliti atau perusahaan sudah mengetahui variabel yang di gunakan dan tujuannya telah diketahui.

Penerapan *machine learning* untuk tujuan pengendalian kualitas dalam meningkatkan produktivitas menjadi fokus utama berdasarkan beberapa artikel yang telah dikumpulkan, di mana algoritma *neural network* menjadi algoritma yang paling banyak digunakan untuk melakukan analisa dan prediksi. Hal ini sangat wajar karena algoritma *neural network* memiliki beberapa kelebihan yang cocok di terapkan dalam pengendalian kualitas, karena algoritma ini ini dapat belajar dari contoh dan menerapkannya ketika peristiwa serupa muncul, membuat mereka dapat bekerja melalui peristiwa yang saat itu terjadi dan Bahkan jika neuron tidak merespons atau ada informasi yang hilang, jaringan dapat mendeteksi kesalahan dan tetap menghasilkan suatu keluaran.

Hasil tinjauan literatur di dapat beberapa potensi untuk dilakukannya penelitian lebih jauh lagi, sehingga diperlukannya suatu fokus penelitian yang lebih persuasif dan lebih mendalam terutama dalam meningkatkan pengembangan produk yang lebih cepat dan mencapai target yang diharapkan. Selain pengembangan produk, penelitian dengan penerapan metode *unsupervised machine learning* masih memiliki potensi yang cukup luas.

Referensi

- Ağbulut, Ü., Gürel, A. E., & Biçen, Y. (2020). Prediction of daily global solar radiation using different machine learning algorithms: Evaluation and comparison. *Renewable and Sustainable Energy Reviews*, 135(August 2020). <https://doi.org/10.1016/j.rser.2020.110114>
- Agrawal, A., Gans, J. S., & Goldfarb, A. (2019). Exploring the impact of artificial Intelligence : Prediction versus judgment. *Information Economics and Policy*, 47, 1–6. <https://doi.org/10.1016/j.infoecopol.2019.05.001>
- Alemdar, H., Tunca, C., & Ersoy, C. (2015). Daily life behaviour monitoring for health assessment using machine learning: bridging the gap between domains. *Personal and Ubiquitous Computing*, 19(February 2015), 303–315. <https://doi.org/10.1007/s00779-014-0823-y>
- Bai, Y., Sun, Z., Deng, J., Li, L., Long, J., & Li, C. (2017). Manufacturing quality prediction using intelligent learning approaches: A comparative study. *Sustainability (Switzerland)*, 10(1), 1–15. <https://doi.org/10.3390/su10010085>
- Bergmann, S., Feldkamp, N., & Strassburger, S. (2017). Emulation of control strategies through machine learning in manufacturing simulations. *Journal of Simulation*, 11(1), 38–50. <https://doi.org/10.1057/s41273-016-0006-0>
- Brito, T., Queiroz, J., Piardi, L., Fernandes, L. A., Lima, J., & Leitão, P. (2020). A Machine Learning Approach for Collaborative Robot Smart Manufacturing Inspection for Quality Control Systems. *Procedia Manufacturing*, 51, 11–18. <https://doi.org/10.1016/j.promfg.2020.10.003>
- Caggiano, A., Zhang, J., Alfieri, V., Caiazza, F., Gao, R., & Teti, R. (2019). Machine learning-based image processing for on-line defect recognition in additive manufacturing. *CIRP Annals*, 68(1), 451–454. <https://doi.org/10.1016/j.cirp.2019.03.021>
- Candanedo, I. S., Nieves, E. H., González, S. R., Martín, M. T. S., & Briones, A. G. (2018). Machine learning predictive model for industry 4.0. *Communications in Computer and Information Science*, 877, 501–510. https://doi.org/10.1007/978-3-319-95204-8_42

- Carvajal Soto, J. A., Tavakolizadeh, F., & Gyulai, D. (2019). An online machine learning framework for early detection of product failures in an Industry 4.0 context. *International Journal of Computer Integrated Manufacturing*, 32(4–5), 452–465. <https://doi.org/10.1080/0951192X.2019.1571238>
- Cavalcante, I. M., Frazzon, E. M., Forcellini, F. A., & Ivanov, D. (2019). A supervised machine learning approach to data-driven simulation of resilient supplier selection in digital manufacturing. *International Journal of Information Management*, 49(March), 86–97. <https://doi.org/10.1016/j.ijinfomgt.2019.03.004>
- Dey, A. (2016). Machine Learning Algorithms: A Review. *International Journal of Computer Science and Information Technologies*, 7(3), 1174–1179. www.ijcsit.com
- Diren, D. D., Boran, S., Selvi, I. H., & Hatipoglu, T. (2019). *Root Cause Detection with an Ensemble Machine Learning Approach in the Multivariate Manufacturing Process*. 163–174. https://doi.org/10.1007/978-3-030-03317-0_14
- Escobar, C. A., & Morales-Menendez, R. (2018). Machine learning techniques for quality control in high conformance manufacturing environment. *Advances in Mechanical Engineering*, 10(2), 1–16. <https://doi.org/10.1177/1687814018755519>
- Fahle, S., Prinz, C., & Kuhlenkötter, B. (2020). Systematic review on machine learning (ML) methods for manufacturing processes - Identifying artificial intelligence (AI) methods for field application. *Procedia CIRP*, 93, 413–418. <https://doi.org/10.1016/j.procir.2020.04.109>
- Filz, M. A., Gellrich, S., Herrmann, C., & Thiede, S. (2020). Data-driven analysis of product state propagation in manufacturing systems using visual analytics and machine learning. *Procedia CIRP*, 93, 449–454. <https://doi.org/10.1016/j.procir.2020.03.065>
- Frank, A. G., Dalenogare, L. S., & Ayala, N. F. (2019). Industry 4 . 0 technologies : Implementation patterns in manufacturing companies. *Intern. Journal of Production Economics*, 210(22 September 2018), 15–26. <https://doi.org/10.1016/j.ijpe.2019.01.004>
- Han, J.-H., Kim, R., & Chi, S.-Y. (2015). *Applications of Machine Learning Algorithms to Predictive Manufacturing*. 51–57. <https://doi.org/10.1145/2837060.2837066>
- Han, J. H., & Chi, S. Y. (2016). Consideration of manufacturing data to apply machine learning methods for predictive manufacturing. *International Conference on Ubiquitous and Future Networks, ICUFN, 2016-Augus*, 109–113. <https://doi.org/10.1109/ICUFN.2016.7536995>
- Hürkamp, A., Gellrich, S., Ossowski, T., Beuscher, J., Thiede, S., Herrmann, C., & Dröder, K. (2020). Combining simulation and machine learning as digital twin for the manufacturing of overmolded thermoplastic composites. *Journal of Manufacturing and Materials Processing*, 4(3). <https://doi.org/10.3390/JMMP4030092>
- Kim, M., Jeong, J., & Bae, S. (2019). Demand forecasting based on machine learning for mass customization in smart manufacturing. *ACM International Conference Proceeding Series*, 6–11. <https://doi.org/10.1145/3335656.3335658>
- Ko, T., Hyuk Lee, J., Cho, H., Cho, S., Lee, W., & Lee, M. (2017). Machine learning-based anomaly detection via integration of manufacturing, inspection and after-sales service data. In *Industrial Management and Data Systems* (Vol. 117, Issue 5). <https://doi.org/10.1108/IMDS-06-2016-0195>
- Lee, J., Davari, H., Singh, J., & Pandhare, V. (2018). Industrial Artificial Intelligence for industry 4.0-based manufacturing systems. *Manufacturing Letters*, 18, 20–23. <https://doi.org/10.1016/j.mfglet.2018.09.002>
- Lee, S., Peng, J., Shin, D., & Choi, Y. S. (2019). Data analytics approach for melt-pool geometries in metal additive manufacturing. *Science and Technology of Advanced Materials*, 20(1), 972–978. <https://doi.org/10.1080/14686996.2019.1671140>
- Li, Z., Liu, R., & Wu, D. (2019). Data-driven smart manufacturing: Tool wear monitoring with audio signals and machine learning. *Journal of Manufacturing Processes*, 48(October 2018), 66–76. <https://doi.org/10.1016/j.jmapro.2019.10.020>

- Li, Z., Zhang, Z., Shi, J., & Wu, D. (2019). Prediction of surface roughness in extrusion-based additive manufacturing with machine learning. *Robotics and Computer-Integrated Manufacturing*, 57(October 2018), 488–495. <https://doi.org/10.1016/j.rcim.2019.01.004>
- Lolli, F., Balugani, E., Ishizaka, A., Gamberini, R., Rimini, B., & Regattieri, A. (2019). Machine learning for multi-criteria inventory classification applied to intermittent demand. *Production Planning and Control*, 30(1), 76–89. <https://doi.org/10.1080/09537287.2018.1525506>
- Lu, H., Li, Y., Chen, M., Kim, H., & Serikawa, S. (2017). Brain Intelligence: Go beyond Artificial Intelligence. *Mobile Netw Appl.*, 23(21 September 2017), 368–375. <https://doi.org/10.1007/s11036-017-0932-8>
- Moldovan, D., Chifu, V., Pop, C., Cioara, T., Anghel, I., & Salomie, I. (2018). Chicken Swarm Optimization and Deep Learning for Manufacturing Processes. *Proceedings - 17th RoEduNet IEEE International Conference: Networking in Education and Research, RoEduNet 2018*, 1–6. <https://doi.org/10.1109/ROEDUNET.2018.8514152>
- Moldovan, D., Cioara, T., Anghel, I., & Salomie, I. (2017). Machine learning for sensor-based manufacturing processes. *Proceedings - 2017 IEEE 13th International Conference on Intelligent Computer Communication and Processing, ICCP 2017*, 147–154. <https://doi.org/10.1109/ICCP.2017.8116997>
- Morariu, C., Răileanu, S., Borangiu, T., & Anton, F. (2019). A distributed approach for machine learning in large scale manufacturing systems. *Studies in Computational Intelligence*, 803, 41–52. https://doi.org/10.1007/978-3-030-03003-2_3
- Morariu, O., Morariu, C., Borangiu, T., & Răileanu, S. (2018). Manufacturing Systems at Scale with Big Data Streaming and Online Machine Learning. *Studies in Computational Intelligence*, 762, 253–264. https://doi.org/10.1007/978-3-319-73751-5_19
- Murphy, R., Newell, A., Hargaden, V., & Papakostas, N. (2019). Machine learning technologies for order flowtime estimation in manufacturing systems. *Procedia CIRP*, 81, 701–706. <https://doi.org/10.1016/j.procir.2019.03.179>
- Nkonyana, T., Sun, Y., Twala, B., & Dogo, E. (2019). Performance evaluation of data mining techniques in steel manufacturing industry. *Procedia Manufacturing*, 35, 623–628. <https://doi.org/10.1016/j.promfg.2019.06.004>
- Oberlé, R., Schorr, S., Yi, L., Glatt, M., Bähre, D., & Aurich, J. C. (2020). A Use Case to Implement Machine Learning for Life Time Prediction of Manufacturing Tools. *Procedia CIRP*, 93, 1484–1489. <https://doi.org/10.1016/j.procir.2020.04.056>
- Paolanti, M., Romeo, L., Felicetti, A., Mancini, A., Frontoni, E., & Loncarski, J. (2018). Machine Learning approach for Predictive Maintenance in Industry 4.0. *2018 14th IEEE/ASME International Conference on Mechatronic and Embedded Systems and Applications, MESA 2018*, 1–6. <https://doi.org/10.1109/MESA.2018.8449150>
- Park, J. K., Kwon, B. K., Park, J. H., & Kang, D. J. (2016). Machine learning-based imaging system for surface defect inspection. *International Journal of Precision Engineering and Manufacturing - Green Technology*, 3(3), 303–310. <https://doi.org/10.1007/s40684-016-0039-x>
- Peres, R. S., Barata, J., Leitao, P., & Garcia, G. (2019). Multistage Quality Control Using Machine Learning in the Automotive Industry. *IEEE Access*, 7, 79908–79916. <https://doi.org/10.1109/ACCESS.2019.2923405>
- Ramamurthy, S. R., & Roy, N. (2018). Recent trends in machine learning for human activity recognition — A survey. *WiRES Data Mining and Knowledge Discovery*, 8(28 March 2018), 1–11. <https://doi.org/10.1002/widm.1254>
- Romeo, L., Loncarski, J., Paolanti, M., Bocchini, G., Mancini, A., & Frontoni, E. (2020). Machine learning-based design support system for the prediction of heterogeneous machine parameters in industry 4.0. *Expert Systems with Applications*, 140. <https://doi.org/10.1016/j.eswa.2019.112869>

- Ruiz, E., Ferreño, D., Cuartas, M., López, A., Arroyo, V., & Gutiérrez-Solana, F. (2020). Machine learning algorithms for the prediction of the strength of steel rods: an example of data-driven manufacturing in steelmaking. *International Journal of Computer Integrated Manufacturing*, 33(9), 880–894. <https://doi.org/10.1080/0951192X.2020.1803505>
- Susto, G. A., Schirru, A., Pampuri, S., McLoone, S., & Beghi, A. (2015). Machine learning for predictive maintenance: A multiple classifier approach. *IEEE Transactions on Industrial Informatics*, 11(3), 812–820. <https://doi.org/10.1109/TII.2014.2349359>
- Syafrudin, M., Alfian, G., Fitriyani, N. L., & Rhee, J. (2018). Performance analysis of IoT-based sensor, big data processing, and machine learning model for real-time monitoring system in automotive manufacturing. *Sensors (Switzerland)*, 18(9). <https://doi.org/10.3390/s18092946>
- Wang, L., Zhang, Y., Chen, X., & Jin, R. (2020). Online Computation Performance Analysis for Distributed Machine Learning Pipelines in Fog Manufacturing. *IEEE International Conference on Automation Science and Engineering*, 2020-Augus, 1628–1633. <https://doi.org/10.1109/CASE48305.2020.9216979>
- Wessel, M., Brandmeier, M., & Tiede, D. (2018). Evaluation of Different Machine Learning Algorithms for Scalable Classification of Tree Types and Tree Species Based on Sentinel-2 Data. *Remote Sensing*, 10(9)(6 September 2018). <https://doi.org/10.3390/rs10091419>
- Wu, D., Jennings, C., Terpenney, J., Gao, R. X., & Kumara, S. (2017). A Comparative Study on Machine Learning Algorithms for Smart Manufacturing: Tool Wear Prediction Using Random Forests. *Journal of Manufacturing Science and Engineering, Transactions of the ASME*, 139(7). <https://doi.org/10.1115/1.4036350>
- Zeng, W., Zhang, B., & Davoodi, A. (2019). Analysis of Security of Split Manufacturing Using Machine Learning. *IEEE Transactions on Very Large Scale Integration (VLSI) Systems*, 27(12), 2767–2780. <https://doi.org/10.1109/TVLSI.2019.2929710>