

Program

Digitalna transformacija robotiziranih tovarnih prihodnosti

DIGITOP

Rezultat D4.1:

Stanje raziskav na področju napovedovanja porabe energije

Projekt/RRP	DIGITOP/ RRp 4.1
Vrsta dokumenta	Poročilo
Verzija dokumenta	1.0
Sodelujoči partnerji	ULFE-LAK, IJS-E2, KOLEKTOR-Sisteh
Avtorji	Gregor Černe, Goran Andonovski, Igor Škrjanc, Miha Glavan, Dejan Gradišar, Viktor Govže, Žiga Stržinar, Marko Mandelj, Andrej Zdešar
Datum priprave	26. 01. 2024

Kazalo

1	UVOD.....	3
2	IZBOLJŠANJE PROIZVODNEGA PLANA IZ VIDIKA ENERGETSKE USTREZNOSTI	3
3	RAZVOJ ENERGETSKEGA DIGITALNEGA DVOJČKA.....	4
4	KOMERCIALNE REŠITVE.....	6
5	ZAKLJUČEK	7
6	BIBLIOGRAFIJA	7

1 Uvod

S pojavom nezanesljivih in volatilnih obnovljivih virov energije (OVE) ter dinamičnih trgov električne energije zmožnost predvidevanja in obvladovanja energetskega vidika proizvodnih procesov postaja vse bolj pomembna. To je posledica nihanja cen na trgu energentov, ki v zadnjem času močno sledijo lastnostim OVE (Mulder & Scholtens, 2013). Zato je ključnega pomena, da proizvodni obrati razvijejo napredne metode za predvidevanje in obvladovanje energetskega vidika svojih proizvodnih procesov. To jim bo to omogočilo zmanjšanje porabljene energije in stroškov proizvodne linije.

Glavni cilj naših raziskav je združiti informacije, ki so običajno že na voljo v proizvodnih IT sistemih, za avtomatizirano izpeljavo energijsko usmerjenih napovednih modelov na podlagi katerih bo zgrajen energetski digitalni dvojček. Naš cilj je razviti algoritme za podatkovno analitiko, ki bodo povezali podatke o proizvodnih procesih s podatki o porabi energije na način. To bo omogočilo algoritmom, da bodo razlikovali osnovne proizvodne operacije, identificirali glavne dejavnike variabilnosti porabe energije, razvili napovedne modele porabe energije za osnovne delovne operacije in združili modele delovnih operacij v končni napovedni model, ki bo predstavljal energetski digitalni dvojček.

Pregled stanja tehnike napovedovanja porabe energije smo opravili za namen ocene energetske ustreznosti proizvodnega plana. Koncept energetske ustreznosti poudarja učinkovito rabo energije, pri čemer se zmanjšujejo izgube, optimizira pretvorba energije in prizadeva za zmanjšanje porabe energije ob hkratnem doseganju enakih ali boljših kakovostnih in stroškovnih rezultatov. Cilj energetske ustreznosti je zmanjšati obremenitev na okolje, stroške energije ter spodbujati trajnostno in odgovorno ravnanje z energijskimi viri.

2 Izboljšanje proizvodnega plana iz vidika energetske ustreznosti

Preden se posvetimo postopkom modeliranja, je koristno pregledati obstoječe metode za izboljšanje plana proizvodnje z vidika energetske ustreznosti. Metodam za izboljšanje plana proizvodnje krajše imenujemo tudi metode razvrščanja (ang. scheduling). S pregledom bomo dobili vpogled v ključne sistemske aspekte, ki jih moramo upoštevati za natančen model energetske ustreznosti. Delo (Gahm, Denz, Dirr, & Tuma, 2016) deli obstoječe metode razvrščanja v tri skupine: metode za izboljšanje energetske ustreznosti, metode, ki upoštevajo značilnosti energetskega povpraševanja in metode, ki upoštevajo značilnosti energetskega povpraševanja.

Metode za izboljšanje energetske ustreznosti se osredotočajo na neposredno zmanjšanje porabe energije, kar poveča energetsko izkoriščenost proizvodnih naprav. Med te spada ukrepi, ko so izklapljanje naprav v stanju pripravljenosti (Mouzon, Yildirim, & Twomey, 2007), sekvenčno vklapljanje naprav ob zagonu proizvodnega procesa (Yildirim & Mouzon, 2012), izvajanje operacij na energetsko bolj učinkovitih napravah (Ji, Wang, & Lee, 2013), zmanjševanje hitrosti operacij (Fang & Lin, 2013), izkoriščanje regeneracije energije (Halim & Srinivasan, 2011) in optimizacija razvrščanja opravil za zmanjšanje porabe energije pri pretvorbi (Rager, Gahm, & Denz, 2015) (Luo, Du, Huang, Chen, & Li, 2013).

Za uspešno izvajanje teh metode je potrebno poglobljeno razumevanje sistema, saj so te metode težko posplošljive in prenosljive med različnimi proizvodnimi obrati.

Metode, ki upoštevajo značilnosti energetskega virov, prilagajajo plan proizvodnje glede na značilnosti posameznih virov energije, predvsem ceno energentov na prostem trgu ter zanesljivost posameznega vira energije. V področju cenovno usmerjenega razvrščanja plana proizvodnje v glavnem obstajajo štiri glavni mehanizmi: definiranje časa porabe, cenitev konične porabe, cenitev v realnem času ter kazni profila porabe. Z definiranjem časa porabe cene definiramo vnaprej (dan, teden, mesec ali leto), kar je uporabno pri kupovanju poceni energije vnaprej (Shrouf, Ordieres-Meré, García-Sánchez, & Ortega-Mier, 2014). Mehanizem cenitev konične porabe zviša ceno v kritičnih konicah porabe električnega sistema (Ashok, 2006), medtem ko mehanizem cenitev v realnem času prilagaja plan proizvodnje glede na urno spreminjanje cen na energetske trgu. Zadnji mehanizem - kazni profila porabe - se osredotoča sledenju v naprej zakupljenemu profilu porabe, saj drugače lahko upravljavec energetskega omrežja kaznuje odjemalca zaradi preobremenitve omrežja (Böning, 2013).

Tretja skupina metod se razvršča z upoštevanjem značilnosti energetskega povpraševanja. V tej skupini metode razvrščanja izkoriščajo lastnosti porabnikov (torej proizvodnih naprav) za izboljšanje energetske ustreznosti. Delo (Liu, Dong, Lohse, Petrovic, & Gindy, 2014) razdeli porabljeno energijo na dva prispevka: porabljena energija za dodano vrednost ter ostala porabljena energija. Porabljena energija za dodano vrednost je tista energija, ki je bila porabljena za operacijo na izdelku. Razvrščanje operacije glede na porabljeno energijo za dodano vrednost je odvisna od lastnosti naprave (Castro, Harjunkoski, & Grossmann, 2011) ter lastnosti izdelka (Agha, Thery, Hetreux, Hait, & Le Lann, 2010). Pod ostalo porabljeno energijo spada tista energija, ki je ne moremo pripisati določenemu izdelku ampak je še vedno potrebna za delovanje proizvodne linije. Primeri, kjer se porablja ostala energije, so zagoni naprav (Shrouf, Ordieres-Meré, García-Sánchez, & Ortega-Mier, 2014), naprave v stanju pripravljenosti (Luo, Du, Huang, Chen, & Li, 2013) ter priprava naprave (Eren & Gautam, 2011).

3 Razvoj energetskega digitalnega dvojčka

Projekt DIGITOP osredotoča razvrščanje z upoštevanjem značilnosti energetskega povpraševanja. Skladno s kategorizacijo napovedovanja porabe energije v delu (Duflou, et al., 2012), projekt zajema prve tri nivoje: nivo naprave, linije in celotnega obrata. Sodobne in visokotehnološke proizvodne linije so pogosto že opremljene z digitalnimi dvojčki (OKUMA EUROPE, 2023), ki vsebujejo podrobne informacije o lastnostih in zmogljivostih, vključno s porabo energije. Te informacije so običajno dovolj natančne za optimizacijo proizvodnega plana.

Vendar mnoge linije, zgrajene v prejšnjem tisočletju, ki še vedno uspešno obratujejo, niso bile zasnovane z mislijo na energetske ustreznost in nimajo sodobnih nadzornih sistemov. Namesto ustavljanja teh produktivnih linij se pojavi potreba po razvoju energetske digitalne dvojčke ali modeliranju energetske porabe, da bi jih vključili v analizo energetske ustreznosti proizvodnega obrata. Modeliranje energetske digitalne dvojčke zajema tri korake: pridobivanje in interpretacijo podatkov, obdelavo in čiščenje podatkov ter samo modeliranje.

Prvi korak v procesu razvoja digitalnega dvojčka je torej **pridobivanje in interpretacija podatkov**, ki igra ključno vlogo pri zagotavljanju natančnosti napovedovanja. Zelo pomemben aspekt modeliranja je izbor vhodnih podatkov (kot so vreme, operater, napake na liniji etc.), saj če nekega vpliva ne vključimo v model, bo dobljen model imel seveda slabšo natančnost napovedovanja. Raziskava (Zhu, et al., 2023) je na primer pokazala, kako

vključitev vremenskih podatkov v model lahko bistveno izboljša napoved porabe energije celotne tovarne. Podobno (Li, Friedrich, & Harrison, 2020) poudarjajo pomen upoštevanja navad uporabnikov, saj lahko te močno vplivajo na končno porabo.

Včasih v planu proizvodnje pot določenega izdelka več (He, Liu, Zhang, Gao, & Liu, 2012), kar zahteva vključitev vseh možnih poti izdelka in oceno verjetnosti za vsako pot (Zhao, Xue, Li, Ping, & Peng, 2021). Lahko se zgodi, da dokler ne začnemo modeliranja porabe, ne dobimo vpogleda kateri podatki so pomembni.

Zanimiv pristop k pridobivanju podatkov predstavlja postopek aktivnega učenja, ki ga opisujejo v delu (Yang, Zhao, Wei, & Zhang, 2019). V tem pristopu algoritem načrtovalcu med grajenjem modela izpostavi specifične vzorce, pri katerih bi z oplemenitenjem nabora vhodnih podatkov dobili boljše rezultate. Tak način učenja je koristen pri težko dostopnih ali dragih podatkih, saj namesto investicije v merilnike vseh spremenljivk procesa, lahko podjetje investira le v tiste, s katerimi bi model lahko izboljšali.

Drugi korak v procesu razvoja energetskega digitalnega dvojčka je **obdelava in čiščenje podatkov**. Surovi podatki pogosto vsebujejo številne napake, ki lahko vključujejo napačne meritve (Hadjout, Sebaa, Torres, & Martínez-Álvarez, 2023), podvojene vnose, prazne vrednosti ali druge anomalije (Atlan, 2023). Kot navajajo (He, et al., 2020), te napake lahko bistveno vplivajo na kakovost končnega modela, zato je še pred začetkom grajenja energetskega dela digitalnega dvojčka potrebno preveriti in popraviti podatke.

Tretji korak v procesu razvoja energetskega digitalnega dvojčka je **modeliranje porabe energije**. Izbor modela in metode učenja je odvisen od specifik naprave, ki jo modeliramo, in od kompleksnosti operacij, ki jih izvaja. Za enostavne operacije lahko predpostavimo konstantne nivoje moči in konstantno trajanje delovanja (Terbrack, Claus, & Herrmann, 2021). V primeru bolj kompleksnih naprav in operacij pa je potrebno napovedati profil porabe, ki je funkcija moči v odvisnosti od pretečenega časa od začetka operacije.

Obstaja veliko načinov, kako opišemo profil porabe, ki je v veliki meri odvisen od vrste naprave in operacije. Delitev naprav na podlagi kompleksnosti modeliranja je predstavljena v delu (Schmidt, Li, Thiede, Kara, & Herrmann, 2015), ki naprave razdeli na več različnih kategorij. Operacijo razdelimo na več posameznih faz s konstantno močjo (primer faz, v angleščini: standby, startup, idle, running, shutdown), ter nato profil sestavimo iz posameznih faz (Pechmann & Schöler, 2011) (Jia, et al., 2021). Namesto deljenja operacije v faze lahko napovedujemo povprečno moč za vsak 15 minut (Keller & Reinhart, 2016).

V nekaterih primerih je sosledje faz znano, vendar samodejno zaznavanje vaz prispeva h hitrejši in enostavnejši integraciji v obstoječ sistem. Posamezna faza je lahko nedeterministična kar je tudi potrebno vključiti v model (nehomogenost vhodnega materiala). En izmed načinov vnašanja nedeterminističnosti je z algoritmom GERT (Zhao, Xue, Li, Ping, & Peng, 2021), na podlagi katerega lahko simuliramo različne poteke izdelka in profil porabe tudi temu primerno opišemo.

V delih (Kong, Dong, Hill, Luo, & Xu, 2018) in (Awad, Mulrennan, Donovan, Macpherson, & Tormey, 2019) pokažejo, da napovedovanje porabe energije posameznih naprav, namesto le ene skupne porabe, omogoči bolj natančne napovedi. Zaradi ekonomske neupravičenosti namestitve merilnikov energije na vse naprave v tovarni, v literaturi najdemo metode, pri katerih se en merilnik postavi za skupino več naprav, nato pa se s pomočjo metod strojnega učenja ugotovi, koliko energije je porabila posamezna naprava. Ta proces imenujemo

disagregacija energije. V delu (Tan, Suvarna, Shee Tan, Li, & Wang, 2021) predstavijo več algoritmov disagregacije za procese, kjer je v eni operaciji tudi več faz. Izbor algoritma je odvisen od vrste učenja. V delu (Tang, et al., 2023) predlagajo napredno strategijo za združevanje naprav, v katerih bomo z disagregacijo dobili boljšo delitev. Številni algoritmi za disagregacijo energije so na voljo pod odprtokodno licenco, kar je dokumentirano v delu (Batra, et al., 2019).

Interpretativnost modela predstavlja pomemben vidik pri generiranju profilov porabe energije, saj zagotavlja, da je postopek, po katerem algoritem pride do rešitve, razumljiv tudi načrtovalcem proizvodnih planov. To pomeni, da lahko načrtovalci hitro identificirajo morebitne napake v modelu in jih učinkovito odpravijo, saj je logika algoritma jasna. V delu (Chen, in drugi, 2021) so dosegli interpretativnost z uporabo fizikalnih lastnosti in Volterovih polinomskih baznih funkcij. Poleg tega spadajo med interpretativne metode tudi mehki modeli, ki so že dokazali svojo uspešnost na področju napovedovanja porabe energije v industrijskem kontekstu (Lau, Cheng, Lee, & Ho, 2008).

Kadar je poraba energije tesno povezana z dimenzijami 3D modela izdelka, kot je to primer pri vlivanju plastike, kjer večji modeli zahtevajo daljše obdobje vlivanja, moramo za natančen profil porabe poznati tudi transformacijo med 3D modelom in porabljeno energijo. To področje je raziskalo delo (Brillinger, in drugi, 2023), ki predstavlja algoritem, ki omogoča oblikovalcem izdelkov, da že med samim načrtovanjem 3D modela vidijo predvideno porabo energije. Prav tako zanimiv pristop je bil predstavljen v delu (Hsiao, 2015), kjer se uporabljata dva zaporedna modela za napovedovanje porabe energije. Prvi model analizira zbrane podatke in ugotovi, kakšen tip vzorca uporabe je trenutno prisoten na napravi. Nato drugi model, na podlagi ocenjenega tipa vzorca uporabe, napove profil porabe energije. Ta metodologija omogoča natančnejše napovedovanje porabe energije, saj upošteva specifične načine uporabe naprav, ki se lahko skozi čas spreminjajo.

Poleg izbire načina zapisa profila porabe energije je ključnega pomena tudi metoda učenja parametrov takšnega profila. V delu (Bermeo-Ayerbe, Ocampo-Martinez, & Diaz-Rozo, 2022) je predstavljena tehnika neinvazivnega opazovanja porabe, s katero določijo parametre dinamičnih modelov posameznih naprav v proizvodnji. Ti modeli so opremljeni tudi z adaptivnim mehanizmom, ki omogoča prilagajanje in učenje v primeru, ko se natančnost napovedi zmanjša zaradi sprememb v strojih ali njihovih modifikacijah. Podoben pristop k sprotneemu učenju se lahko uporabi z nevronskimi mrežami LSTM (Long Short-Term Memory), demonstrirano v delu (Morariu, Morariu, Răileanu, & Borangiu, 2020). Še en način sprotnega učenja je »transfer learning« (Zhou, Zhai, Li, & Shi, 2023), kjer znanje, naučeno na zgodovinskih podatkih, prenesemo na nove probleme.

4 Komercialne rešitve

V komercialnem sektorju je storitev napovedovanja porabe energije običajno vključena skupaj z rešitvijo nadzora proizvodnje. To izhaja iz dejstva, da samostojni modeli energetske ustreznosti brez integracije v proizvodni proces ne prinašajo neposrednih prihrankov. Zaradi tega se proizvodni obrati pogosto odločajo za model napovedovanja, ki je že vključen v njihove obstoječe programske rešitve za načrtovanje proizvodnje. Med podjetji, ki ponujajo takšne celovite rešitve, so PlantTogether, ki so ga uspešno implementirali v proizvodnji embalaže (PlanetTogether, 2023), Siemens (Siemens, SIMATIC Energy Management Software, 2024), ki kot produkt prodaja tudi upravljanje z energetskimi podatki (primer v živilski industriji (Siemens, Energy data

management in the food and beverage industry, 2024)), saj je upravljanje ključno za dobro analizo, General Electric (General Electric Company, 2019), ABB (ABB, 2024), METRONIK (Metronik, 2024), INOSIM (Inosim, 2024) ter ORSOFT (Orsoft, 2024).

5 Zaključek

V literaturi pa nismo zasledili metod, ki sproti gradile model porabe električne energije in sproti tudi izbirale model (več kot imamo vzorcev, bolj kompleksen model lahko uporabimo). Cilj takšne metode je enostavnost uporabe, saj takšna metoda ne potrebuje naprednega znanja modeliranja za uporabo, hkrati jo pa hitro implementiramo v obstoječo linijo brez dodatnih stroškov.

6 Bibliografija

- ABB. (2024). Industrial energy forecasting and load planning software. *Industrial energy forecasting and load planning software*. Pridobljeno 11. January 2024 iz <https://new.abb.com/industrial-software/sustainability/energy-management-system-enms/industrial-energy-load-planning-forecasting-scheduling>
- Agha, M. H., Thery, R., Hetreux, G., Hait, A., & Le Lann, J. M. (2010). Integrated production and utility system approach for optimizing industrial unit operations. *Energy*, 35, 611–627.
- Ahmad, T., & Chen, H. (2018). Utility companies strategy for short-term energy demand forecasting using machine learning based models. *Sustainable Cities and Society*, 39, 401–417.
- Ashok, S. (2006). Peak-load management in steel plants. *Applied Energy*, 83, 413–424.
- Atlan. (2023). Bad Data: How It Sneaks in & How to Manage It in 2024. *Bad Data: How It Sneaks in & How to Manage It in 2024*. Pridobljeno 16. January 2024 iz <https://atlan.com/what-is-bad-data/>
- Awad, M., Mulrennan, K., Donovan, J., Macpherson, R., & Tormey, D. (2019). Energy Consumption Profiling - A Case Study in a Batch Manufacturing Facility. *Iape'19*, 1–5.
- Bangsow, S. (2012). *Use cases of discrete event simulation: Appliance and research* (Izv. 9783642287).
- Batra, N., Kukunuri, R., Pandey, A., Malakar, R., Kumar, R., Krystalakos, O., . . . Parson, O. (2019). Towards reproducible state-of-the-art energy disaggregation. 193–202.
- Bermeo-Ayerbe, M. A., Ocampo-Martinez, C., & Diaz-Rozo, J. (2022). Data-driven energy prediction modeling for both energy efficiency and maintenance in smart manufacturing systems. *Energy*, 238, 121691.
- Böning, C. (2013). *Entwicklung einer Methode zu energiekostenorientierten Belegungsplanung*. Tech. rep., Bundesministerium für Wirtschaft und Technologie, Hannover. Pridobljeno iz https://www.bvl.de/files/1951/2125/2131/2133/16904_EnKoBel_Schlussbericht_2013.pdf
- Braeuer, F., Rominger, J., McKenna, R., & Fichtner, W. (2019). Battery storage systems: An economic model-based analysis of parallel revenue streams and general implications for industry. *Applied Energy*, 239, 1424–1440.
- Brillinger, M., Wuwer, M., Smajic, B., Abdul Hadi, M., Trabesinger, S., Oberegger, B., & Jäger, M. (2023). Novel method to predict the energy consumption of machined parts in the design phase to attain sustainability goals. *Journal of Manufacturing Processes*, 101, 1046–1054.
- Castro, P. M., Harjunkoski, I., & Grossmann, I. E. (2011). Optimal scheduling of continuous plants with energy constraints. *Computers and Chemical Engineering*, 35, 372–387.

- Chen, S., Gong, F., Zhang, M., Yuan, J., Liao, S., Chen, H., . . . Hu, X. (2021). Planning and scheduling for industrial demand-side management: State of the art, opportunities and challenges under integration of energy internet and industrial internet. *Sustainability (Switzerland)*, 13.
- Duflou, J. R., Sutherland, J. W., Dornfeld, D., Herrmann, C., Jeswiet, J., Kara, S., . . . Kellens, K. (2012). Towards energy and resource efficient manufacturing: A processes and systems approach. *CIRP Annals - Manufacturing Technology*, 61, 587–609.
- Eren, E. C., & Gautam, N. (2011). Efficient control for a multi-product quasi-batch process via stochastic dynamic programming. *IIE Transactions (Institute of Industrial Engineers)*, 43, 192–206.
- Fang, K. T., & Lin, B. M. (2013). Parallel-machine scheduling to minimize tardiness penalty and power cost. *Computers and Industrial Engineering*, 64, 224–234.
- Gahm, C., Denz, F., Dirr, M., & Tuma, A. (2016). Energy-efficient scheduling in manufacturing companies: A review and research framework. *European Journal of Operational Research*, 248, 744–757.
- General Electric Company. (2019). *Data-Driven Energy: The Advanced Energy Management Solution*. Tech. rep., General Electric Company. Pridobljeno iz https://www.ge.com/digital/sites/default/files/download/_assets/data-driven-energy-the-advanced-energy-management-solution-ge-digital.pdf
- Hadjout, D., Sebaa, A., Torres, J. F., & Martínez-Álvarez, F. (2023). Electricity consumption forecasting with outliers handling based on clustering and deep learning with application to the Algerian market. *Expert Systems with Applications*, 227, 120123.
- Halim, I., & Srinivasan, R. (2011). Sequential methodology for integrated optimization of energy and water use during batch process scheduling. *Computers and Chemical Engineering*, 35, 1575–1597.
- He, Y., Liu, B., Zhang, X., Gao, H., & Liu, X. (2012). A modeling method of task-oriented energy consumption for machining manufacturing system. *Journal of Cleaner Production*, 23, 167–174.
- He, Y., Wu, P., Li, Y., Wang, Y., Tao, F., & Wang, Y. (2020). A generic energy prediction model of machine tools using deep learning algorithms. *Applied Energy*, 275, 115402.
- Hsiao, Y. H. (2015). Household electricity demand forecast based on context information and user daily schedule analysis from meter data. *IEEE Transactions on Industrial Informatics*, 11, 33–43.
- Inosim. (2024). Inosim software. *Inosim software*. Pridobljeno 11. January 2024 iz <https://www.inosim.com/offerings/inosim-software/>
- Ji, M., Wang, J. Y., & Lee, W. C. (2013). Minimizing resource consumption on uniform parallel machines with a bound on makespan. *Computers and Operations Research*, 40, 2970–2974.
- Jia, S., Cai, W., Liu, C., Zhang, Z., Bai, S., Wang, Q., . . . Hu, L. (2021). Energy modeling and visualization analysis method of drilling processes in the manufacturing industry. *Energy*, 228, 120567.
- Keller, F., & Reinhart, G. (2016). Energy Supply Orientation in Production Planning Systems. *Procedia CIRP*, 40, 244–249.
- Keller, F., & Reinhart, G. (2016). Energy Supply Orientation in Production Planning Systems. *Procedia CIRP*, 40, 244–249.
- Kong, W., Dong, Z. Y., Hill, D. J., Luo, F., & Xu, Y. (2018). Short-term residential load forecasting based on resident behaviour learning. *IEEE Transactions on Power Systems*, 33, 1087–1088.
- Lau, H. C., Cheng, E. N., Lee, C. K., & Ho, G. T. (2008). A fuzzy logic approach to forecast energy consumption change in a manufacturing system. *Expert Systems with Applications*, 34, 1813–1824.
- Li, Z., Friedrich, D., & Harrison, G. P. (2020). Demand forecasting for a mixed-use building using agent-schedule information with a data-driven model. *Energies*, 13.
- Liu, Y., Dong, H., Lohse, N., Petrovic, S., & Gindy, N. (2014). An investigation into minimising total energy consumption and total weighted tardiness in job shops. *Journal of Cleaner Production*, 65, 87–96.
- Luo, H., Du, B., Huang, G. Q., Chen, H., & Li, X. (2013). Hybrid flow shop scheduling considering machine electricity consumption cost. *International Journal of Production Economics*, 146, 423–439.

- Luo, H., Du, B., Huang, G. Q., Chen, H., & Li, X. (2013). Hybrid flow shop scheduling considering machine electricity consumption cost. *International Journal of Production Economics*, 146, 423–439.
- Metronik. (2024). Energy Management. *Energy Management*. Pridobljeno 12. January 2024 iz https://www.ge.com/digital/sites/default/files/download/_assets/data-driven-energy-the-advanced-energy-management-solution-ge-digital.pdf
- Morariu, C., Morariu, O., Răileanu, S., & Borangiu, T. (2020). Machine learning for predictive scheduling and resource allocation in large scale manufacturing systems. *Computers in Industry*, 120.
- Morbidoni, A., Favi, C., & Germani, M. (2011). *CAD-integrated LCA tool: Comparison with dedicated LCA software and guidelines for the improvement*.
- Mouzon, G., Yildirim, M. B., & Twomey, J. (2007). Operational methods for minimization of energy consumption of manufacturing equipment. *International Journal of Production Research*, 45, 4247–4271.
- Mulder, M., & Scholtens, B. (2013). The impact of renewable energy on electricity prices in the Netherlands. *Renewable Energy*, 57, 94–100.
- Mulrennan, K., Awad, M., Donovan, J., Macpherson, R., & Tormey, D. (2020). Modelling the electrical energy profile of a batch manufacturing pharmaceutical facility. *International Journal of Data Science and Analytics*, 10, 285–300.
- Mulrennan, K., Awad, M., Donovan, J., Macpherson, R., & Tormey, D. (2020). Modelling the electrical energy profile of a batch manufacturing pharmaceutical facility. *International Journal of Data Science and Analytics*, 10, 285–300.
- OKUMA EUROPE, G. M. (2023). Next generation CNC control. *Next generation CNC control*. Pridobljeno 19. January 2024 iz <https://www.okuma.eu/newsroom/press-releases/detail/next-generation-cnc-control/>
- Orsoft. (2024). Saving energy in industry without expensive investments in production facilities. *Saving energy in industry without expensive investments in production facilities*. Pridobljeno 11. January 2024 iz <https://www.orsoft.net/en/solutions-concepts/advanced-planning-scheduling/energy-planning-sustainability/>
- Pechmann, A., & Schöler, I. (2011). Optimizing Energy Costs by Intelligent Production Scheduling. V J. Hesselbach, & C. Herrmann (Ured.), *Glocalized Solutions for Sustainability in Manufacturing* (str. 293–298). Berlin, Heidelberg: Springer Berlin Heidelberg. Pridobljeno iz <https://link.springer.com/10.1007/978-3-642-19692-8> https://link.springer.com/10.1007/978-3-642-19692-8_51
- PlanetTogether. (2023). Energy-Efficient Production Scheduling: Revolutionizing Packaging Manufacturing. *Energy-Efficient Production Scheduling: Revolutionizing Packaging Manufacturing*. Pridobljeno 10. January 2024 iz <https://www.planettogether.com/blog/energy-efficient-production-scheduling-revolutionizing-packaging-manufacturing>
- Rager, M., Gahm, C., & Denz, F. (2015). Energy-oriented scheduling based on Evolutionary Algorithms. *Computers and Operations Research*, 54, 218–231.
- Reimann, J., Wenzel, K., Friedemann, M., & Putz, M. (2018). Methodology and model for predicting energy consumption in manufacturing at multiple scales. *Procedia Manufacturing*, 21, 694–701.
- Schmidt, C., Li, W., Thiede, S., Kara, S., & Herrmann, C. (2015). A methodology for customized prediction of energy consumption in manufacturing industries. *International Journal of Precision Engineering and Manufacturing - Green Technology*, 2, 163–172.
- Shrouf, F., Ordieres-Meré, J., García-Sánchez, A., & Ortega-Mier, M. (2014). Optimizing the production scheduling of a single machine to minimize total energy consumption costs. *Journal of Cleaner Production*, 67, 197–207.
- Siemens. (2024). *Energy data management in the food and beverage industry*. Tech. rep., Siemens. Pridobljeno iz <https://www.siemens.com/global/en/industries/food-beverage/exclusive-area/whitepaper-energydatamanagment.html>

- Siemens. (2024). *SIMATIC Energy Management Software*. Pridobljeno 12. January 2024 iz SIMATIC Energy Management Software: <https://www.siemens.com/global/en/products/automation/industry-software/automation-software/energymangement.html>
- Stecca, M., Elizondo, L. R., Soeiro, T. B., Bauer, P., & Palensky, P. (2020). A comprehensive review of the integration of battery energy storage systems into distribution networks. *IEEE Open Journal of the Industrial Electronics Society*, 1, 46–65.
- Tan, D., Suvarna, M., Shee Tan, Y., Li, J., & Wang, X. (2021). A three-step machine learning framework for energy profiling, activity state prediction and production estimation in smart process manufacturing. *Applied Energy*, 291, 116808.
- Tang, Y., Tang, Z., Gao, Y., Wei, L., Zhou, J., Han, F., & Liu, J. (2023). An adaptive forecasting method for the aggregated load with pattern matching. *Frontiers in Energy Research*, 10, 1–8.
- Terbrack, H., Claus, T., & Herrmann, F. (2021). Energy-oriented production planning in industry: A systematic literature review and classification scheme. *Sustainability (Switzerland)*, 13, 1–32.
- Yang, J., Zhao, X., Wei, H., & Zhang, K. (2019). Sample Selection Based on Active Learning for Short-Term Wind Speed Prediction. *Energies*, 12, 337.
- Yildirim, M. B., & Mouzon, G. (2012). Single-machine sustainable production planning to minimize total energy consumption and total completion time using a multiple objective genetic algorithm. *IEEE Transactions on Engineering Management*, 59, 585–597.
- Zhang, Z., Zhou, K., & Yang, S. (2023). Optimal selection of energy storage system sharing schemes in industrial parks considering battery degradation. *Journal of Energy Storage*, 57, 106215.
- Zhao, J., Xue, Z., Li, T., Ping, J., & Peng, S. (2021). An energy and time prediction model for remanufacturing process using graphical evaluation and review technique (GERT) with multivariant uncertainties. *Environmental Science and Pollution Research*, 2020.
- Zhou, X., Zhai, N., Li, S., & Shi, H. (2023). Time Series Prediction Method of Industrial Process With Limited Data Based on Transfer Learning. *IEEE Transactions on Industrial Informatics*, 19, 6872–6882.
- Zhu, Z., Zhou, M., Hu, F., Wang, S., Ma, J., Gao, B., . . . Lai, W. (2023). A day-ahead industrial load forecasting model using load change rate features and combining FA-ELM and the AdaBoost algorithm. *Energy Reports*, 9, 971–981.