



10. Veštačka inteligencija i mašinsko učenje u lancima snabdevanja

Šta je veštačka inteligencija (AI)? Da li je to stvarno "živo" stvorenje sposobno razmišljati i donositi sopstvene odluke na osnovu svog uma, prošlih iskustava, etike, uverenja itd.? Kako je to povezano sa mašinskim učenjem (engl. *machine learning* - ML)? Jesu li AI i ML ista stvar?

Koji se alati koriste u AI & ML? Koju ulogu imaju AI i ML u poslovnom kontekstu i kako se mogu koristiti u svakodnevnim poslovnim procesima i optimizacijama? Da li postoje specifične arhitekture i primeri primene AI-a i ML-a na lance snabdevanja?

Na ova i slična pitanja pokušaćemo dati odgovore u sledećem poglavlju, završavajući stvarnim primerom studije slučaja primene AI & ML algoritama u distributivnom skladištu.

10.1 Šta je veštačka inteligencija?

Područje veštačke inteligencije započelo je 1950-ih kada su se stručnjaci za računare zapitali: "Da li računari mogu razmišljati kao ljudi"? Istraživači su u to vreme bili oduševljeni mogućnošću učenja računara da izvršavaju složene zadatke i u skladu s tim razvili su skup različitih algoritama za tu svrhu. Definicija ovog polja mogla bi se navesti kao napor da se automatizuju intelektualni zadaci koje obično obavljaju ljudi (Chollet, 2021). Algoritmi u području veštačke inteligencije danas dolaze iz ML-a i dubokog učenja, koji su podskupovi AI-a. Osim ML-a i dubokog učenja, AI uključuje i mnogo algoritama koji nisu učeći. Štaviše, u ranoj fazi razvoja veštačke inteligencije, ovi su algoritmi bili dominantniji. Prema tome, taj deo veštačke inteligencije poznat je kao simbolička veštačka inteligencija koja se bazira na ideji da se može postići ljudski nivo performansi i inteligencije programiranjem računara s velikim skupom eksplicitnih pravila za rešavanje posmatranog problema. Ovaj pristup dao je izvrsne rezultate u logičkom problemu koji je bio dobro definisan, poput računara koji igra šah, ali se pokazao komplikovanim za složenije probleme. Stvarni svet se pokazao puno komplikovanijim nego što bi se sva eksplicitna pravila programiranja mogla uneti u računar.



Ovaj pristup je fokusiran na ideju za datu situaciju - učini ovo ili ono (ako-onda pravila). Ovo je lako razumljiv pristup, ali s druge strane vrlo dugotrajan i ponekad je jako teško odrediti sve moguće scenarije koje je potrebno uneti u program. Kao smešan primer, ali dobra ilustracija ove teme, pogledajte sliku 10.1 koja prikazuje nekoliko scenarija za određivanje prognoze na osnovu statusa kamena.




Slika 4.58 Ako – Onda pravila programiranja (Gibbs, 2019).

Područje simboličke veštačke inteligencije najveću je popularnost steklo 1980-ih s pojavom ekspertskih sistema (ES). ES predstavljaju podskup sistema za podršku odlučivanju (DSS) (Turban, 1998), usmerenih na pružanje sposobnosti računarima da donose odluke sličnih onima koje donose stručnjaci unutar određenog područja. Ovi su sistemi izrađeni za rešavanje zamršenih problema upotrebom niza pravila ili algoritama koji simuliraju procese ljudskog zaključivanja. Olson i Courtney (1992) opisuju ekspertске sisteme (ES) kao računarske programe koji simuliraju ljudske misaone procese za donošenje odluka unutar određenog domena, uključujući stepen veštačke inteligencije koji odgovara zaključcima do kojih bi ljudski stručnjak došao. ES komponenta je posebno korisna za podršku donosiocima odluka u područjima koja zahtevaju specijalizovana znanja (Turban i dr., 2005). U osnovi, ES prikuplja ekspertizu ljudskog stručnjaka (ili drugog izvora) i prenosi je na računar. Ova tehnologija može ili pomoći donosiocima odluka ili ih u potpunosti zameniti, što je čini jednim od najšire primenjivanih i komercijalno najuspešnijih oblika veštačke inteligencije (Turban i dr., 2005). Jedan od ključnih razloga za razvoj ES-a je distribucija stručnog znanja široj publici (Jackson, 1999). U sledećim potpoglavljima, demonstriraće se primena ES-a



zasnovanog na AI i ML algoritmima, menadžerima u centralnom skladištu kao delu celokupnog DSS-a.

Danas se područje veštačke inteligencije sastoji od različitih pristupa i algoritama, no oni koji se najviše koriste opisani su na slici 10.2. Razišlo se od ES sistema, a za ponovni razvoj ovog područja najviše su zaslužni algoritmi dubokog učenja koji su u posljednjih 12 godina imali značajan uspjeh u problemima prepoznavanja slike, govora, segmentacije slike, prepoznavanja lica itd. Duboko učenje koristi više slojeva apstrakcije za prepoznavanje složenih uzoraka u visokodimenzionalnim podacima. Ovaj pristup je postigao značajan napredak u područjima kao što su prepoznavanje govora i slike, otkrivanje lekova i obrada prirodnog jezika. Duboko učenje ima sposobnost automatskog otkrivanja relevantnih obeležja, smanjuje potrebu za ljudskom intervencijom u dizajnu obeležja, što ga čini vrlo uspešnim u iskorišćavanju velikih skupova podataka i snage računara (LeCun i dr., 2015).



Slika 4.59 Glavna polja i potpolja AI
(Athanasopoulou i dr., 2022).



Veliki korak prema današnjoj situaciji bilo je istraživanje klasifikacije vrednosti koje su sprovedi Hinton i dr. (2006), koje je uspelo postići više od 98% tačnosti na klasifikaciji baze podataka Modifikovanog nacionalnog instituta za standarde i tehnologiju (engl. *Modified National Institute of Standards and Technology* - MNIST). Jedan od načina razmišljanja o tome kako je veštačka inteligencija prešla iz simboličke veštačke inteligencije u ML i šta je suština ML-a jeste zamisliti ML algoritme kao amorfnu masu koja se sama oblikuje prema željenim ishodima. Sistem pravila koji uzima input u output menja se od problema do problema i prilagođava postojećem stanju. Cilj mu je pronaći pravila koja će automatizovati zadatak traženjem statističkih obrazaca unutar podataka. Ovakav pristup rešavanju različitih problema značajno smanjuje vreme postavljanja sistema (u poređenju sa ako – onda pravilima) i čini ga univerzalnijim pristupom za rešavanje različitih problema.

Bengio i dr. (2021) naglasili su da je budućnost veštačke inteligencije u dubokom učenju i revolucionarnom uticaju meke pažnje i transformatorskih arhitektura u veštačkoj inteligenciji. Ove inovacije omogućavaju neuronskim mrežama da se dinamički fokusiraju na važne ulaze i skladište informacije u diferencijalnim memorijama, značajno poboljšavajući sekvencijalnu obradu.

10.2 Šta je ekosistem AI-a i ML-a?

Ekosistem AI i ML algoritama sastoji se od tri ključna stuba:

- Ulazni podaci;
- Izlazni podaci;
- Funkcija troška.

Ulazni podaci predstavljaju zapise podataka određenih karakteristika ili karakteristike (zavisno od uočenog problema). Tačnost ulaznih podataka ključna je za izgradnju tačnih algoritama. To često nije slučaj u stvarnim aplikacijama i obično se značajno vreme i trud posvećuju prikupljanju podataka, čišćenju, argumentaciji, objedinjavanju, proveru lažnih unosa itd. Osim tačnih podataka, drugi važan aspekt karakteristika ulaznih podataka je njihova reprezentacija i kodiranje. Različiti načini kodiranja podataka mogu otkriti različite karakteristike podataka i značajno "pomoći" ML modelima u otkrivanju skrivenih obrazaca u podacima. Ovde vidimo Ahilovu petu ML algoritama. Često se previše pažnje posvećuje



kreiranju metoda za izvlačenje informacija i inteligencije iz podataka (tj. samih algoritama), dok se premalo pažnje posvećuje ulaznim podacima i njihovom odnosu s izlaznim podacima. Generalno se podrazumeva da su ulazni podaci u uzročno-posledičnoj vezi s izlaznim podacima, što ponekad uopšte nije slučaj. Stoga bi sledeći veliki korak u razvoju ML-a trebao biti pronalaženje boljih načina za prikupljanje, predstavljanje i kodiranje podataka.

Izlazni podaci predstavljaju merenja određenog problema koji pokušavamo rešiti. U problemu klasifikacije, to bi bila oznaka klase. U regresiji, to će biti stvarni broj koji pokušavamo predvideti. U kontekstu specifičnog problema, za probleme s prepoznavanjem govora, izlazni podaci mogu biti ljudski generisani zapisi zvučnih datoteka. U problemu prepoznavanja slike, izlaz može biti oznaka klase slike, itd.

Troškovna funkcija predstavlja način merenja učinka AI i ML. U osnovi, idealno bismo želeli da odgovori algoritama odgovaraju izlaznim podacima, za date ulazne podatke. Troškovna funkcija takođe je povratni signal skupu parametara koji usmeravaju rad algoritma, tj. omogućuje optimizaciju realizacije algoritma kroz proces učenja (pronalaženje optimalnog skupa parametara). Proces učenja obično uključuje nadzirano učenje, gde se model trenira na označenim podacima kako bi se smanjile greške predviđanja pomoću tehnika kao što su stohastički gradijentni spuštanje i širenje unazad. To omogućava modelu da uspešno prilagodi svoje unutrašnje parametre, što dovodi do poboljšane realizacije zadataka kao što su otkrivanje i klasifikacija objekata (LeCun i dr. 2015).

10.3 Koji se alati koriste u ML-u?

Generalno, ML algoritmi mogu se klasifikovati u dvije glavne kategorije: nadzirano i nenadzirano učenje.

Nadzirano učenje uključuje uvežbavanje algoritama na označenom skupu podataka, gde je svaka ulazna tačka podataka uparena s tačnim izlazom. Ova jasna "slika" o tome kakav bi trebao biti tačan odgovor za dati ulaz omogućava algoritmu da nauči funkciju mapiranja od ulaza do izlaza. Shodno tome, poznati su i ulazni i izlazni podaci (Athanasopoulou i dr., 2022). Uobičajene primene nadziranog učenja uključuju zadatke klasifikacije (npr. određivanje da li je e-pošta spam ili ne) i zadatke regresije (npr. predviđanje cena kuća na osnovu različitih karakteristika). Neki od najpopularnijih algoritama koji su dokazani brojnim primenama su generalizovani aditivni modeli, slučajne šume, boosting, klasifikaciona i



regresiona stabla, potporni vektorski uređaji, proširena linearna regresija, logistička regresija, k-najbliži susedi, linearna diskriminantna analiza, laso, neuronske mreže, adaptivni neuro-fuzzy sistem zaključivanja itd. (Rostami-Tabar i Mircetic, 2023). Nadzirano učenje je moćno jer iskorišćava podatke koje su komentarisali ljudi za postizanje visoke tačnosti u predviđanjima. Međutim, njegova učinkovitost uveliko zavisi od kvaliteta i količine označenih podataka.

Nasuprot tome, nenadzirano učenje bavi se skupovima podataka koji nemaju označene odgovore. Shodno tome, algoritmi nenadziranog mašinskog učenja koriste neoznačene skupove podataka koji uključuju samo ulaze (Athanasopoulou i dr., 2022). Ovde se algoritam daje samo s ulaznim podacima, a cilj mu je pronaći osnovne obrasce, strukture ili odnose unutar podataka. Uobičajene tehnike učenja bez nadzora uključuju grupisanje (npr. grupisanje kupaca prema kupovnom ponašanju) i smanjenje dimenzionalnosti (npr. smanjenje broja varijabli u skupu podataka uz zadržavanje važnih informacija). Nenadzirano učenje dragocjeno je za istraživačku analizu podataka i otkrivanje skrivenih struktura u podacima. Često se koristi kada su označeni podaci retki ili nedostupni.

Još jedna važna kategorija, iako se razlikuje od nadziranog i nenadziranog učenja, jeste podržano učenje (engl. *reinforcement learning*). Ovde algoritam uči interakcijom s okolinom i primanjem povratnih informacija u obliku nagrada ili kazni. Ovaj pristup pokušaja i greške pomaže algoritmu da nauči optimalne aktivnosti kako bi maksimizirao kumulativne nagrade. Podržano učenje široko se koristi u područjima kao što su robotika, igranje igrica i autonomni sistemi.

Jedan od najpopularnijih i najuspešnijih algoritama za ML dolazi iz oblasti neuronskih mreža. Neuronske mreže postoje od 1950-ih, ali su svoju popularnost stekle 1980-ih i u poslednjih 12 godina. Izgrađene su na aproksimaciji bioloških neurona i načina na koji dele delove informacija u mozgu, ali osim toga, nema značajnih međusobnih veza. Danas se najčešće koristi oblik neuronskih mreža u obliku dubokog učenja, koji predstavlja nekoliko skrivenih slojeva između ulaznih i izlaznih karakteristika, koji izvode nekoliko nelinearnih transformacija ulaznih karakteristika. Budući da se ovo pokazalo vrlo uspešnim, duboko učenje danas je jedno od najistaknutijih potpodručja mašinskog učenja (Chollet, 2021).



10.4 Studija slučaja?

Nalazi Wenzela i dr. (2019) o ML-u u upravljanju lancem snabdevanja ukazuju na rastuću integraciju ML aplikacija u različitim zadacima lanca snabdevanja. Shodno tome, posmatrana studija slučaja predstavlja primenu AI-a i ML-a, izvedenu u centralnom skladištu fabrike hrane (Mirčetić i dr., 2016; Mirčetić i dr., 2014). U krugu fabrike nalazi se 30 viljuškara. Viljuškari su angažovani na različitim poslovima unutar kompleksa koji su ključni za logističke poslove u proizvodnji, skladištenju i otpremi proizvoda. Centralno skladište ima kapacitet od 11.100 paletnih mesta i godišnju proizvodnju od 300.000 do 350.000 paleta. Trenutno fabrika direktnom dostavom snabdeva oko 20.000 prodavnica.

Problem angažovanja viljuškara povezan je s činjenicom da preveliko ili premalo angažovanje viljuškara u različitim fabričkim procesima dovodi do značajnih finansijskih i tržišnih gubitaka. Trenutno se proces donošenja odluka gde će i šta će koji viljuškar raditi, bazira na odlukama stručnjaka (menadžera). Stručne odluke zasnovane su na njihovom iskustvu, bez pomoći bilo kakvog sistema za podršku odlučivanju (DSS). Brojni empirijski dokazi sugerišu da ljudska intuitivna procena i donošenje odluka često nisu optimalni, posebno u uslovima složenosti i stresa (Druzdzel i Flynn, 2002). Ovo naglašava važnost uključivanja sistema za podršku odlučivanju (DSS) koji pomažu stručnjacima u procesu donošenja odluka.

U ovoj aplikaciji odabrali smo nekoliko ML algoritama za pomoć u optimizaciji operacija otpremnog skladišta. ML algoritmi sastavljeni su u jedinstveni okvir za donošenje odluka koji služi kao DSS za menadžere i stručnjake u određenoj kompaniji. Štaviše, celi DSS za donošenje odluka može se posmatrati kao AI platforma, budući da stalno preračunava predloge iz nekoliko ML modela (koliko i koje viljuškare koristiti) i automatski bira one najbolje, s obzirom na dostavljene unose operatera.

Opis problema


Proces utovara ključan je za skladišnu logistiku i utiče na nivo tržišne usluge. Tokom otpreme, skladišni stručnjak određuje broj i vrši izbor viljuškara za utovar, vođen sa tri faktora: (1) dovršetak utovara unutar navedenog vremenskog okvira, (2) minimiziranje ometanja drugih zadataka viljuškara i (3) usklađivanje upotrebe viljuškara s mogućnostima održavanja, koje mogu podneti dva remonta istovremeno. Svaki viljuškar prolazi četiri do pet remonta godišnje.



Viljuškari su vitalni za procese utovara, koji moraju podržati marketinšku strategiju kompanije, a istovremeno osigurati nesmetanu realizaciju ostalih aktivnosti. Pogrešna raspodela viljuškara može dovesti do neiskorišćenosti resursa ili naštetiti ugledu kompanije i nivou usluge. Kašnjenja u utovaru povlače kazne. Menadžer mora koordinirati korišćenje viljuškara u svim aktivnostima kako bi izbegao istovremene remonte i upravljao različitim potrebama održavanja. Iako menadžeri obično donose tačne odluke, okruženje visokog stresa može dovesti do grešaka. Stoga je DSS potreban za povećanje poverenja i pouzdanosti donošenja odluka.

AI i ML kao DSS za centralno skladište


Prvi korak za generisanje AI i ML sistema je sticanje stabilnog i ispravnog izvora znanja (baza podataka) i rasvetljavanje poslovnih uloga koje treba podržavati. Stoga slika 10.3 predstavlja metodologiju za izgradnju AI i ML DSS sistema.



Slika 4.60Metodološki koraci za izgradnju AI i ML DSS sistema (Rainer i Turban, 2008; Turban i dr., 2005).

Sticanje znanja ostvareno je razgovorima s menadžerima, posmatranjem njihovih procesa donošenja odluka i pregledom skladišne dokumentacije. Za razvoj DSS-a za navedeni problem uspostavljene su dve baze znanja. Prva baza znanja uključuje odluke o broju viljuškara raspoređenih u zoni utovara (434 stručne odluke), dok druga pokriva koji su viljuškari korišćeni (368 stručnih odluka) u različitim operativnim scenarijima. Tokom faze zaključivanja znanja primenjeno je nekoliko ML algoritama pomoću Matlab softvera: Adaptivni neuro-fuzzy sistem zaključivanja (ANFIS), generalizovani aditivni modeli (GAM), slučajne šume, boosting, klasifikaciona i regresiona stabla (CART), proširena linearna regresija, logistička regresija, k-najbliži susedi (KNN) i linearna diskriminantna analiza (LDA). Procenjeni su različiti ML modeli i identifikovani su oni s najboljim performansama. ANFIS i CART pokazali su vrhunske rezultate i odabrani su kao konačni DSS-ovi za praktičnu primenu

u kompaniji. Prenos znanja je omogućen kroz korisnički interfejs finalnih DSS modela. Struktura i logika DSS-a ilustrovana je na slici 10.4.



Slika 4.61 Izgradnja strukture skladišnog DSS-a na osnovu AI i ML algoritama.

DSS okvir sastoji se od ulaznog sloja koji se sastoji od nekoliko ključnih faktora koji utiču na uključivanje viljuškara. ML sloj ima ML modele koji ponovno izračunavaju predlog o tome koliko i koje viljuškare koristiti u datom scenariju unosa. Modeli s najboljim učinkom biraju se kao modeli ekspertske sistema (ES modeli) budući da se baza znanja na kojoj se formiraju ML modeli izdvaja od stručnjaka. Prvi model fokusiran je na određivanje broja viljuškara potrebnih u zoni utovara (ES model 1). Drugi model bavi se problemom izbora pojedinačnih viljuškara koji će se angažovati (ES model 2). Oba modela razvijena su korišćenjem nadziranih tehnika mašinskog učenja. Prema Turbanu i dr. (2005.), mašinsko učenje je pokazalo izvrsne rezultate u dizajniranju inteligentnih sistema za podršku odlučivanju (DSS). ES modeli šalju signale (ML sugestije i predloge) dalje u operaciju sortiranja, gde svaki viljuškar koji je klasifikovan u grupi sortiranja „Da“, može biti angažovan u određenom procesu utovara.


Konsultacijama su identifikovani faktori koji utiču na odluke menadžera. Za određivanje broja viljuškara u zoni utovara, ključni faktori su navedeno vreme utovara (15 do 135 minuta) i



količina tereta (15 do 225 paleta). Prilikom izbora viljuškara koje će angažovati, menadžer uzima u obzir važnost trenutne aktivnosti (ocenjuje se od 1 do 9 prema politici kompanije), stepen iskorišćenja viljuškara, njegovu udaljenost od zone za utovar i prosečni stepen iskorišćenja svih viljuškara. Svaki viljuškar ima određeni broj radnih sati pre nego što je potreban remont, a njegova je uporaba ograničena izvan tog ograničenja. Iskorišćenje viljuškara (engl. *Forklift Utilization* - FU) je procenat radnih sati koje koristi pojedinačni viljuškar, dok je prosečna iskorišćenost viljuškara (engl. *Average Forklift Utilization* - AFU) prosečno radno vreme svih viljuškara. Veći AFU sugerise da će većini viljuškara uskoro trebati remont.

Korisnički interfejs DSS-a


U većini situacija unosa najbolja izvedba je pokazana putem ANFIS-a i CART-a. Shodno tome, oni su odabrani kao pokretači datog DSS-a i njegovih ES-ova. Korisnički interfejs ES modela 1 prikazan je na slici 10.5, a operaterima omogućava brzo i jednostavno donošenje odluka o broju viljuškara za postavljanje jednostavnim pomeranjem vertikalne linije kroz domen ulaznih varijabli, na osnovu navedenog vremena utovara i količine tereta.



Slika 4.62Sistem neizrazitog zaključivanja ES modela 1.

ES Model 2 služi kao dopunski alat ES Modelu 1, poboljšavajući donošenje odluka dajući informacije o tome da li treba određeni viljuškar biti postavljen u zoni utovara (slika 10.6). Uzimajući u obzir položaj viljuškara (udaljenost od zone utovara), njegovu trenutnu aktivnost (važnost aktivnosti), njegovu iskorišćenost radnih sati (FU) i prosečnu iskorišćenost svih viljuškara (AFU), korisnici mogu lako utvrditi da li je određeni viljuškar prikladan za utovar ili

treba odabrati neki drugi. CART stablo odlučivanja je jednostavno za tumačenje, eliminišući potrebu za unosom vrednosti u softver. Umesto toga, stablo sa slike 10.6 može se ispisati i istaknuti u skladištu za brzu referencu.



Slika 4.63 Stablo odlučivanja ES modela 2 u vezi s uključivanjem viljuškara.

Menadžeri mogu svakodnevno koristiti predstavljeni DSS, koji pomaže u postizanju boljeg odgovora lanca snabdevanja na zahteve kupaca i osiguravajući visoku verovatnoću isporuka na vreme. Predloženi AI & ML DSS pokazao je uspešne rezultate u sticanju "know-how" stručnog znanja i hvatanju "logike zaključivanja". Korišćenjem ove metode, stručnost menadžera može se izdvojiti i primeniti na druge skladišne procese. Ovo je posebno važno i vredno za praktičare jer je angažovanje stručnjaka za skladištenje često skupo. Osim toga, DSS takođe može poslužiti kao alat za obuku menadžera početnika, pomažući im da steknu iskustvo i poboljšaju svoje veštine donošenja odluka tokom vremena. Stoga su AI i ML sistemi koji mogu simulirati odluke menadžera ključni alati koji nude značajne uštede troškova i povećanu učinkovitost u skladišnim operacijama.

Literatura 10. poglavlja

- Athanasopoulou, K., Daneva, G. N., Adamopoulos, P. G., & Scorilas, A. (2022). Artificial intelligence: The milestone in modern biomedical research. *BioMedInformatics*, 2(4), 727-744. <https://doi.org/10.3390/biomedinformatics2040049>



- Bengio, Y., Lecun, Y., & Hinton, G. (2021). Deep learning for AI. *Communications of the ACM*, 64(7), 58-65.
- Chollet, F. (2021). *Deep learning with Python*. Simon and Schuster.
- Druzdel, M. J., & Flynn, R. R. (2002). Decision support systems. In A. Kent (Ed.), *Encyclopedia of library and information science* (2nd ed.). Marcel Dekker, Inc.
- Gibbs, M. (2019, December 17). Table-driven programming and the weather forecasting stone. *Global Nerdy*. <https://www.globalnerdy.com/2019/12/17/table-driven-programming-and-the-weather-forecasting-stone/>
- Hinton, G. E., Osindero, S., & Teh, Y. W. (2006). A fast learning algorithm for deep belief nets. *Neural computation*, 18(7), 1527-1554.
- Jackson, P. (1999). *Introduction to expert systems*. Addison-Wesley.
- LeCun, Y., Bengio, Y., & Hinton, G. (2015). Deep learning. *Nature*, 521(7553), 436-444.
- Mirčetić, D., Ralević, N., Nikolić, S., Maslarić, M., & Stojanović, Đ. (2016). Expert system models for forecasting forklifts engagement in a warehouse loading operation: A case study. *Promet-Traffic & Transportation*, 28(4), 393-401.
- Mircetic, D., Lalwani, C., Lirn, T., Maslaric, M., & Nikolicic, S. (2014, July). ANFIS expert system for cargo loading as part of decision support system in warehouse. In *19th International Symposium on Logistics (ISL 2014)*.
- Rostami-Tabar, B., & Mircetic, D. (2023). Exploring the association between time series features and forecasting by temporal aggregation using machine learning. *Neurocomputing*, 548, 126376.
- Olson, D. L., & Courtney, J. F. (1992). *Decision support models and expert systems*. Macmillan.
- Rainer, R. K., & Turban, E. (2008). *Introduction to information systems: Supporting and transforming business*. John Wiley & Sons.
- Turban, E. (1998). *Decision support and expert systems* (2nd ed.). Macmillan.
- Turban, E., Aronson, J., & Liang, T.-P. (2005). *Decision support systems and intelligent systems* (7th ed.). Pearson Prentice Hall.
- Wenzel, H., Smit, D., & Sardesai, S. (2019). A literature review on machine learning in supply chain management. In W. Kersten, T. Blecker, & C. M. Ringle (Eds.), *Artificial Intelligence and Digital Transformation in Supply Chain Management: Innovative Approaches for Supply Chains* (Vol. 27, pp. 413-441). <https://doi.org/10.15480/882.2478>