



10. Umjetna inteligencija i strojno učenje u opskrbnim lancima

Što je umjetna inteligencija (AI)? Je li to stvarno "živo" stvorenje sposobno razmišljati i donositi vlastite odluke na temelju svog uma, prošlih iskustava, etike, uvjerenja itd.? Kako je to povezano sa strojnim 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 operacijama i optimizacijama? Postoje li specifične arhitekture i primjeri primjene AI-a i ML-a na opskrbne lance?

Na ova i slična pitanja pokušat ćemo dati odgovore u sljedećem poglavlju, završavajući stvarnim primjerom studije slučaja primjene AI & ML algoritama u distribucijskom skladištu.

10.1 Što je umjetna inteligencija?

Područje umjetne inteligencije započelo je 1950-ih kada su se računalni znanstvenici zapitali: "Mogu li računala razmišljati kao ljudi"? Istraživači su u to vrijeme bili oduševljeni mogućnošću učenja računala 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 automatiziraju intelektualni zadaci koje obično obavljaju ljudi (Chollet, 2021). Algoritmi u području umjetne 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. Štoviše, u ranoj fazi razvoja umjetne inteligencije, ovi su algoritmi bili dominantniji. Prema tome, taj dio umjetne inteligencije poznat je kao simbolička umjetna inteligencija koja se temelji na ideji da se može postići ljudska razina performansi i inteligencije programiranjem računala s velikim skupom eksplicitnih pravila za rješavanje promatranog problema. Ovaj pristup dao je izvrsne rezultate u logičkom problemu koji je bio dobro definiran, poput računala koje igra šah, ali se pokazao kompliciranim za složenije probleme. Stvarni svijet se pokazao puno kompliciranijim nego što bi se sva eksplicitna pravila programiranja mogla unijeti u računalo. Ovaj pristup je usredotočen na ideju za danu 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 unijeti u program. Kao smiješan primjer, ali dobra ilustracija ove teme, pogledajte sliku 10.1 koja prikazuje nekoliko scenarija za određivanje prognoze na temelju statusa kamena.




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

Područje simboličke umjetne inteligencije najveću je popularnost steklo 1980-ih s pojavom ekspertnih sustava (ES). ES predstavljaju podskup sustava za podršku odlučivanju (DSS) (Turban, 1998), usmjerenih na pružanje računalnih sposobnosti donošenja odluka sličnih onima stručnjaka unutar određenog područja. Ovi su sustavi izrađeni za rješavanje zamršenih problema upotrebom niza pravila ili algoritama koji simuliraju procese ljudskog zaključivanja. Olson i Courtney (1992) opisuju ekspertne sustave (ES) kao računalne programe koji simuliraju ljudske misaone procese za donošenje odluka unutar određene domene, uključujući stupanj umjetne inteligencije koji odgovara zaključcima do kojih bi ljudski stručnjak došao. ES komponenta je posebno korisna za podršku donositeljima odluka u područjima koja zahtijevaju specijalizirana znanja (Turban i dr., 2005). U osnovi, ES prikuplja ekspertizu ljudskog stručnjaka (ili drugog izvora) i prenosi je na računalo. Ova tehnologija može ili pomoći donositeljima odluka ili ih u potpunosti zamijeniti, što je čini jednim od najšire primjenjivanih i komercijalno najuspješnijih oblika umjetne inteligencije (Turban i dr., 2005). Jedan od ključnih razloga za razvoj ES-a je distribucija stručnog znanja široj publici (Jackson, 1999). U sljedećim potpoglavljima, demonstrirat ćemo primjenu ES-a temeljenog na AI i ML algoritmima, u centralnom skladištu kao dijelu cjelokupnog DSS-a menadžerima.

Danas se područje umjetne inteligencije sastoji od različitih pristupa i algoritama, no oni koji se najviše koriste opisani su na slici 10.2. Razišlo se od ES sustava, 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, prepoznavanja 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 lijekova i obrada prirodnog jezika. Duboko učenje ima sposobnost automatskog otkrivanja relevantnih obilježja smanjuje potrebu za ljudskom intervencijom u dizajnu obilježja, što ga čini vrlo učinkovitim u iskorištavanju velikih skupova podataka i računalne snage (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 znamenki koje su proveli Hinton i dr. (2006), koje je uspjelo postići više od 98% točnosti na klasifikaciji baze podataka Modificiranog nacionalnog instituta za standarde i tehnologiju (engl. *Modified National Institute of Standards and Technology* - MNIST). Jedan od načina razmišljanja o tome kako je umjetna inteligencija prešla iz simboličke umjetne inteligencije u ML i što je bit ML-a jest zamisliti ML



algoritme kao amorfnu masu koja se sama oblikuje prema željenim ishodima. Sustav pravila koji uzima input u output mijenja se od problema do problema i prilagođava postojećem stanju. Cilj mu je pronaći pravila koja će automatizirati zadatak traženjem statističkih obrazaca unutar podataka. Ovakav pristup rješavanju različitih problema značajno smanjuje vrijeme postavljanja sustava (u usporedbi s ako – onda pravilima) i čini ga univerzalnijim pristupom za rješavanje različitih problema.

Bengio i dr. (2021) naglasili su da je budućnost umjetne inteligencije u dubokom učenju i revolucionarnom utjecaju meke pažnje i transformatorskih arhitektura u umjetnoj inteligenciji. Ove inovacije omogućuju neuronskim mrežama da se dinamički fokusiraju na važne ulaze i pohranjuju informacije u diferencijalne memorije, značajno poboljšavajući sekvencijalnu obradu.

10.2 Što je ekosustav AI-a i ML-a?

Ekosustav AI i ML algoritama sastoji se od tri ključna stupa:

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

Ulazni podaci predstavljaju zapise podataka određene značajke ili značajki (ovisno o uočenom problemu). Točnost ulaznih podataka ključna je za izgradnju točnih algoritama. To često nije slučaj u stvarnim aplikacijama i obično se značajno vrijeme i trud posvećuju prikupljanju podataka, čišćenju, argumentiranju, objedinjavanju, provjeri lažnih unosa itd. Osim točnih podataka, drugi važan aspekt karakteristika ulaznih podataka je njihova reprezentacija i kodiranje. Različiti načini kodiranja podataka mogu otkriti različite značajke podataka i značajno "pomoći" ML modelima u otkrivanju skrivenih obrazaca u podacima. Ovdje vidimo Ahilovu petu ML algoritama. Često se previše pozornosti posvećuje kreiranju metoda za izvlačenje informacija i inteligencije iz podataka (tj. samih algoritama), dok se premalo pozornosti posvećuje ulaznim podacima i njihovom odnosu s izlaznim podacima. Općenito se podrazumijeva da su ulazni podaci u uzročno-posljedičnoj vezi s izlaznim podacima, što ponekad uopće nije slučaj. Stoga bi sljedeći veliki korak u razvoju ML-a trebao biti pronalaženje boljih načina za prikupljanje, predstavljanje i kodiranje podataka.



Izlazni podaci predstavljaju mjerenja određenog problema koji pokušavamo riješiti. U problemu klasifikacije, to bi bila oznaka klasa. U regresiji, to će biti stvarni broj koji pokušavamo predvidjeti. U kontekstu specifičnog problema, za probleme s prepoznavanjem govora, izlazni podaci mogu biti ljudski generirani prijepisi zvučnih datoteka. U problemu prepoznavanja slike, izlaz može biti oznaka klase slike, itd.

Troškovna funkcija predstavlja način mjerenja izvedbe AI i ML. U osnovi, idealno bismo željeli da odgovori algoritama odgovaraju izlaznim podacima, za dane ulazne podatke. Troškovna funkcija također je povratni signal skupu parametara koji usmjeravaju rad algoritma, tj. omogućuje optimizaciju ukupne izvedbe algoritma kroz proces učenja (pronalaženje optimalnog skupa parametara). Proces učenja obično uključuje nadzirano učenje, gdje se model trenira na označenim podacima kako bi se smanjile pogreške predviđanja pomoću tehnika kao što su stohastički gradijentni spuštanje i širenje unazad. To omogućuje modelu da učinkovito prilagodi svoje unutarnje parametre, što dovodi do poboljšane izvedbe zadataka kao što su otkrivanje i klasifikacija objekata (LeCun i dr. 2015).

10.3 Koji se alati koriste u ML-u?

Općenito, ML algoritmi mogu se klasificirati u dvije glavne kategorije: nadzirano i nenadzirano učenje.

Nadzirano učenje uključuje uvježbavanje algoritama na označenom skupu podataka, gdje je svaka ulazna podatkovna točka uparena s točnim izlazom. Ova jasna "slika" o tome kakav bi trebao biti točan odgovor za dati ulaz omogućuje algoritmu da nauči funkciju mapiranja od ulaza do izlaza. Sukladno tome, poznati su i ulazni i izlazni podaci (Athanasopoulou i dr., 2022). Uobičajene primjene nadziranog učenja uključuju zadatke klasifikacije (npr. određivanje je li e-pošta spam ili ne) i zadatke regresije (npr. predviđanje cijena kuća na temelju različitih značajki). Neki od najpopularnijih algoritama koji su dokazani brojnim primjenama su generalizirani aditivni modeli, slučajne šume, boosting, klasifikacijska i regresijska stabla, potporni vektorski strojevi, proširena linearna regresija, logistička regresija, k-najbliži susjedi, linearna diskriminantna analiza, laso, neuronske mreže, adaptivni neuro-fuzzy sustav zaključivanja itd. (Rostami-Tabar i Mircetic, 2023). Nadzirano učenje je moćno jer iskorištava podatke koje su komentirali ljudi za postizanje visoke točnosti u predviđanjima. Međutim, njegova učinkovitost uvelike ovisi o kvaliteti i količini označenih podataka.



Nasuprot tome, nenadzirano učenje bavi se skupovima podataka koji nemaju označene odgovore. Sukladno tome, algoritmi nenadziuranog strojnog učenja koriste neoznačene skupove podataka koji uključuju samo ulaze (Athanasopoulou i dr., 2022). Ovdje se algoritam daje samo s ulaznim podacima, a cilj mu je pronaći temeljne obrasce, strukture ili odnose unutar podataka. Uobičajene tehnike učenja bez nadzora uključuju grupiranje (npr. grupiranje 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 rijetki ili nedostupni.

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

Jedan od najpopularnijih i najuspješnijih algoritama za ML dolazi iz grane neuronskih mreža. Neuronske mreže postoje od 1950-ih, ali su svoju popularnost stekle 1980-ih i u posljednjih 12 godina. Izgrađeni su na aproksimaciji bioloških neurona i načina na koji dijele dijelove informacija u mozgu, ali osim toga, nema značajnih veza između njih dvoje. Danas se najčešće koristi oblik neuronskih mreža u obliku dubokog učenja, koji predstavlja nekoliko skrivenih slojeva između ulaznih i izlaznih značajki, koji izvedu nekoliko nelinearnih transformacija ulaznih značajki. Budući da se ovo pokazalo vrlo uspješnim, duboko učenje danas je jedno od najistaknutijih potpodručja strojnog učenja (Chollet, 2021).

10.4 Studija slučaja?

Nalazi Wenzela i dr. (2019) o ML-u u upravljanju opskrbnim lancem ukazuju na rastuću integraciju ML aplikacija u različitim zadacima opskrbnog lanca. Sukladno tome, promatrana studija slučaja predstavlja primjenu AI-a i ML-a, izvedenu u centralnom skladištu tvornice hrane (Mirčetić i dr., 2016; Mirčetić i dr., 2014). U krugu tvornice nalazi se 30 viličara. Viličari su angažirani 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 mjesta i godišnju proizvodnju od 300.000 do 350.000 paleta. Trenutno tvornica izravnom dostavom opskrbljuje oko 20.000 prodavaonica.

Problem angažmana viličara povezan je s činjenicom da preveliki ili premali angažman viličara u različitim tvorničkim procesima dovodi do značajnih financijskih i tržišnih gubitaka. Trenutno se proces donošenja odluka gdje će i što će koji viličar raditi temelji na odlukama stručnjaka (menadžera). Stručne odluke temelje se na njihovom iskustvu, bez pomoći bilo kakvog sustava za podršku odlučivanju (DSS). Brojni empirijski dokazi sugeriraju da ljudska intuitivna prosudba i donošenje odluka često nisu optimalni, osobito u uvjetima složenosti i stresa (Druzdzel i Flynn, 2002). Ovo naglašava važnost uključivanja sustava za podršku odlučivanju (DSS) koji pomažu stručnjacima u procesu donošenja odluka.

U ovoj aplikaciji odabrali smo nekoliko ML algoritama za pomoć u optimizaciji operacija utovarnog skladišta. ML algoritmi sastavljeni su u jedinstveni okvir za donošenje odluka koji služi kao DSS za menadžere i stručnjake u određenoj tvrtki. Štoviše, cijeli DSS za donošenje odluka može se promatrati kao AI platforma, budući da stalno preračunava prijedloge iz nekoliko ML modela (koliko viličara koristiti i koje) i automatski odabire one najbolje, s obzirom na dostavljene unose operatera.

Opis problema


Proces utovara ključan je za skladišnu logistiku i utječe na razinu tržišne usluge. Tijekom otpreme, skladišni stručnjak određuje broj i izbor viličara za utovar, vođen trima čimbenicima: (1) dovršetak utovara unutar navedenog vremenskog okvira, (2) minimiziranje ometanja drugih zadataka viličara i (3) usklađivanje upotrebe viličara s održavanjem mogućnosti, koje mogu podnijeti dva remonta istovremeno. Svaki viličar prolazi četiri do pet remonta godišnje.

Viličari su vitalni za operacije utovara, koje moraju podržati marketinšku strategiju tvrtke, a istodobno osigurati nesmetan rad ostalih aktivnosti. Pogrešna raspodjela viličara može dovesti do neiskorištenosti resursa ili naštetiti ugledu tvrtke i razini usluge. Kašnjenja u utovaru povlače kazne. Upravitelj mora koordinirati korištenje viličara u svim aktivnostima kako bi izbjegao istovremene remonte i upravljao različitim potrebama održavanja. Iako menadžeri obično donose točne odluke, okruženja visokog stresa mogu dovesti do pogrešaka. Stoga je DSS potreban za povećanje povjerenja i pouzdanosti donošenja odluka.




AI i ML kao DSS za centralno skladište

Prvi korak za generiranje AI i ML sustava je stjecanje stabilnog i ispravnog izvora znanja (baza podataka) i rasvjetljavanje poslovnih uloga koje treba podržavati. Stoga slika 10.3 predstavlja metodologiju za izgradnju AI i ML DSS sustava.



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

Stjecanje znanja ostvareno je razgovorima s menadžerima, promatranjem njihovih procesa donošenja odluka i pregledom skladišne dokumentacije. Za razvoj DSS-a za navedeni problem uspostavljene su dvije baze znanja. Prva baza znanja uključuje odluke o broju viličara raspoređenih u zoni utovara (434 stručne odluke), dok druga pokriva koji su viličari korišteni (368 stručnih odluka) u različitim operativnim scenarijima. Tijekom faze zaključivanja znanja primijenjeno je nekoliko ML algoritama pomoću Matlab softvera: Adaptivni neuro-fuzzy sustav zaključivanja (ANFIS), generalizirani aditivni modeli (GAM), slučajne šume, boosting, klasifikacijska i regresijska stabla (CART), proširena linearna regresija, logistička regresija, k-najbliži susjedi (KNN) i linearna diskriminantna analiza (LDA). Procijenjeni su različiti ML modeli i identificirani su oni s najboljim performansama. ANFIS i CART pokazali su vrhunske rezultate i odabrani su kao konačni DSS-ovi za praktičnu primjenu u tvrtki. Prijenos znanja je omogućen kroz korisničko sučelje finalnih DSS modela. Struktura i logika DSS-a ilustrirana je na slici 10.4.



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

DSS okvir sastoji se od ulaznog sloja koji se sastoji od nekoliko ključnih čimbenika koji utječu na uključivanje viličara. ML sloj ima ML modele koji ponovno izračunavaju prijedlog o tome koliko i koje viličare koristiti u danom scenariju unosa. Modeli s najboljim učinkom biraju se kao modeli ekspertnih sustava (ES modeli) budući da se baza znanja na kojoj se stvaraju ML modeli izdvaja od stručnjaka. Prvi model fokusiran je na određivanje broja viličara potrebnih u zoni utovara (ES model 1). Drugi model bavi se problemom odabira koji će se specifični viličari angažirati (ES model 2). Oba modela razvijena su korištenjem nadziranih tehnika strojnog učenja. Prema Turbanu i dr. (2005.), strojno učenje je pokazalo izvrsne rezultate u dizajniranju inteligentnih sustava za podršku odlučivanju (DSS). ES modeli šalju signale (ML sugestije i prijedloge) dalje u operaciju sortiranja, gdje svaki viličar koji je klasificiran u grupi sortiranja „Da“, može biti angažiran u određenoj operaciji utovara.


Konzultacijama su identificirani čimbenici koji utječu na odluke menadžera. Za određivanje broja viličara za raspoređivanje u zoni utovara, ključni čimbenici su navedeno vrijeme utovara (15 do 135 minuta) i količina tereta (15 do 225 paleta). Prilikom odabira viličara koje će angažirati, upravitelj uzima u obzir važnost trenutne aktivnosti (ocjenjuje se od 1 do 9 prema politici tvrtke), stopu iskorištenja viličara, njegovu udaljenost od pristaništa za utovar i prosječnu stopu iskorištenja svih viličara. Svaki viličar ima određeni broj radnih sati prije nego što je potreban remont, a njegova je uporaba ograničena izvan tog ograničenja. Iskorištenje



viličara (engl. *Forklift Utilization* - FU) je postotak radnih sati koje koristi pojedinačni viličar, dok je prosječna iskorištenost viličara (engl. *Average Forklift Utilization* - AFU) prosječno radno vrijeme svih viličara. Veći AFU sugerira da će većina viličara uskoro trebati remont.


Korisničko sučelje DSS-a

U većini situacija unosa najbolja izvedba je pokazana putem ANFIS-a i CART-a. Sukladno tome, oni su odabrani kao pokretači danog DSS-a i njegovih ES-ova. Korisničko sučelje ES modela 1 prikazano je na slici 10.5, a operaterima omogućuje brzo i jednostavno donošenje odluka o broju viličara za postavljanje jednostavnim pomicanjem okomite linije kroz domenu ulaznih varijabli, na temelju navedenog vremena utovara i količine tereta.



Slika 4.62Sustav neizrazitog zaključivanja ES modela 1.

ES Model 2 služi kao dopunski alat ES Modelu 1, poboljšavajući donošenje odluka dajući informacije o tome treba li određeni viličar biti postavljen u zoni utovara (slika 10.6). Uzimajući u obzir položaj viličara (udaljenost od zone utovara), njegovu trenutnu aktivnost (važnost aktivnosti), njegovu iskorištenost radnih sati (FU) i prosječnu iskorištenost svih viličara (AFU), korisnici mogu lako utvrditi je li određeni viličar prikladan za utovar ili treba odabrati neki drugi. CART stablo odlučivanja je jednostavno za tumačenje, eliminirajući potrebu za unosom vrijednosti u softver. Umjesto 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 viličara.

Menadžeri mogu svakodnevno koristiti predstavljeni DSS, pomažući u postizanju boljeg odgovora opskrbnog lanca na zahtjeve kupaca i osiguravajući visoku vjerojatnost isporuke na vrijeme. Predloženi AI & ML DSS pokazao je uspješne rezultate u stjecanju stručnjakovog "know-how" znanja i hvatanju njihove "logike zaključivanja". Korištenjem ove metode, stručnost menadžera može se izdvojiti i primijeniti na druge skladišne operacije. Ovo je osobito vrijedno za praktičare jer je angažiranje stručnjaka za skladištenje često skupo. Osim toga, DSS također može poslužiti kao alat za obuku menadžera početnika, pomažući im da steknu iskustvo i poboljšaju svoje vještine donošenja odluka tijekom vremena. Stoga su AI i ML sustavi 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.
- Druzdzel, 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., Nikoličić, 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>