



10. Umetna inteligenca in strojno učenje v oskrbovalnih verigah

Kaj je umetna inteligenca (AI)? Ali je to res "živo" bitje, ki je sposobno razmišljati in sprejemati lastne odločitve na podlagi svojega uma, preteklih izkušenj, etike, prepričanj itd.? Kako je povezana s strojnim učenjem (ML)? Ali sta umetna inteligenca in računalniško učenje ena in ista stvar?

Katera orodja se uporabljajo pri umetni inteligenci in ML? Kakšno vlogo imata AI in ML v poslovnem kontekstu in kako ju je mogoče uporabiti pri vsakodnevnih poslovnih operacijah in optimizacijah? Ali obstajajo posebne arhitekture in primeri uporabe UI in ML v oskrbovalnih verigah?

Na ta in podobna vprašanja bomo poskušali odgovoriti v naslednjem poglavju, ki ga bomo zaključili s primerom študije primera uporabe algoritmov AI in ML v distribucijskem skladišču.

10.1 Kaj je umetna inteligenca?

Področje umetne inteligence se je začelo v petdesetih letih prejšnjega stoletja, ko so se računalniški znanstveniki spraševali: "Ali lahko računalniki razmišljajo kot ljudje?" Takratni raziskovalci so bili navdušeni nad možnostjo, da bi računalnike naučili opravljati zapletene naloge, in so v ta namen razvili vrsto različnih algoritmov. Opredelitev področja bi lahko navedli kot prizadevanje za avtomatizacijo intelektualnih nalog, ki jih običajno opravljajo ljudje (Chollet, 2021). Najznamenitejši algoritmi na področju umetne inteligence danes izhajajo iz ML in globokega učenja, ki sta podskupini umetne inteligence. Poleg ML in globokega učenja AI vključuje tudi veliko algoritmov, ki se ne učijo. Poleg tega lahko trdimo, da so te vrste algoritmov bolj prevladovali v zgodnji fazi razvoja UI. V skladu s tem je to del UI, znan kot simbolna UI, ki temelji na ideji, da je mogoče človeško raven zmogljivosti in inteligence doseči s programiranjem računalnikov z velikim naborom eksplicitnih pravil za reševanje opazovanega problema. Ta pristop je zagotavljal odlične rezultate pri logičnih problemih, ki so bili dobro opredeljeni, kot je na primer računalnik, ki igra šahovsko partijo, vendar se je pri bolj zapletenih problemih izkazal za zapletenega. Izkazalo se je, da je resnični svet veliko bolj zapleten, kot bi lahko v računalnik vstavili vsa eksplicitna programska pravila. Ta pristop je osredotočen na zamisel za določeno situacijo naredi to ali ono (pravila if-then). To je lahko razumljiv pristop, vendar po drugi strani zelo zamuden in včasih zelo težaven za določitev vseh možnih scenarijev, ki jih je treba vstaviti v program. Kot smešen primer, vendar

dobro ponazoritev določene teme, si oglejte sliko 10.1, ki prikazuje več scenarijev za določanje napovedi na podlagi stanja kamna.




Slika 10.1 Programsko pravila If - Then (Gibbs, M. 2019).

Področje simbolne umetne inteligence je bilo najbolj priljubljeno v osemdesetih letih prejšnjega stoletja s pojavom ekspertnih sistemov (ES). ES predstavljajo podmnžico sistemov za podporo odločanju (DSS) (Turban, 1998), ki se osredotočajo na zagotavljanje računalniških zmožnosti odločanja, podobnih tistim, ki jih imajo človeški strokovnjaki na določenem področju. Ti sistemi so zasnovani za reševanje zapletenih problemov z uporabo vrste pravil ali algoritmov, ki simulirajo procese človeškega razmišljanja. Olson in Courtney opisujeta ekspertne sisteme (ES) kot računalniške programe, ki simulirajo človeške miselne procese za sprejemanje odločitev na določenem področju in vključujejo določeno stopnjo umetne inteligence, da bi ustrezali sklepom, do katerih bi prišel človeški strokovnjak (Olson in Courtney, 1992). Komponenta ES je še posebej uporabna za podporo odločevalcem na področjih, ki zahtevajo specializirano znanje (Turban et al., 2005). V bistvu ES zajame strokovno znanje človeškega strokovnjaka (ali drugega vira) in ga prenese na računalnik. Ta tehnologija lahko pomaga nosilcem odločanja ali pa jih v celoti nadomesti, zaradi česar je ena od najbolj razširjenih in komercialno uspešnih oblik umetne inteligence (Turban et al., 2005). Eden od ključnih razlogov za razvoj ES je razširjanje strokovnega znanja širšemu občinstvu (Jackson, 1999). V naslednjih podpoglavjih bomo prikazali uporabo ES, ki temelji na algoritmih AI & ML, v osrednjem skladišču kot delu celotnega DSS za upravitelje.

Danes področje umetne inteligence sestavljajo različni pristopi in algoritmi, vendar so najbolj uporabljeni opisani na sliki 10.2. Odmaknilo se je od sistemov ES, za ponovni vzpon področja pa so najbolj zaslužni algoritmi globokega učenja, ki so bili v zadnjih 12 letih zelo uspešni pri problemih prepoznavanja slik, govora, segmentacije slik, prepoznavanja obrazov itd. Globoko učenje

uporablja več plasti abstrakcije za prepoznavanje zapletenih vzorcev v visokodimenzionalnih podatkih. Ta pristop je dosegel pomemben napredek na področjih, kot so prepoznavanje govora in slik, odkrivanje zdravil in obdelava naravnega jezika. Globoko učenje ima sposobnost samodejnega odkrivanja ustreznih lastnosti in zmanjšuje potrebo po človeškem posredovanju pri oblikovanju lastnosti, zaradi česar je zelo učinkovito pri izkoriščanju velikih zbirk podatkov in računalniške moči (LeCun, Bengio in Hinton, 2015).



Slika 10.2 Glavna področja in podpodročja umetne inteligence (Athanasopoulou et al., 2022).

Velik korak k današnjemu stanju je bila raziskava klasifikacije števil, ki so jo opravili Hinton, Osindero in Teh (2006), ki jim je uspelo doseči več kot 98-odstotno natančnost pri klasifikaciji podatkovne baze MNIST (Modified National Institute of Standards and Technology). Eden od načinov razmišljanja o tem, kako je umetna inteligenca prešla iz simbolne v ML in kaj je bistvo ML, je, da si algoritme ML predstavljamo kot amorfnu maso, ki se oblikuje glede na želene rezultate. Sistem pravil, ki od vhoda do izhoda sprejema podatke, se spreminja od problema do problema in se prilagaja obstoječim razmeram. Njegov cilj je poiskati pravila, ki bodo avtomatizirala nalogo z iskanjem statističnih vzorcev v podatkih. Zaradi tovrstnega pristopa k reševanju različnih problemov se je bistveno skrajšal čas za vzpostavitev sistema (v primerjavi s pravili če - potem), poleg tega pa je bolj univerzalen pristop za reševanje različnih problemov.



Bengio, Lecun in Hinton (2021) so poudarili, da je prihodnost umetne inteligence v globokem učenju ter revolucionarnem vplivu mehke pozornosti in transformatorskih arhitektur na umetno inteligenco. Te inovacije nevronske mreže omogočajo, da se dinamično osredotočajo na pomembne vhodne podatke in shranjujejo informacije v diferencialne pomnilnike, kar bistveno izboljša zaporedno obdelavo.

10.2 Kakšen je ekosistem umetne inteligence in računalništva na podlagi podatkov?

Ekosistem algoritmov AI in ML sestavljajo trije ključni stebri:

- Vhodni podatki;
- Izhodni podatki;
- Stroškovna funkcija.

Vhodni podatki so zapisi podatkov o določeni lastnosti ali lastnostih (glede na opazovano težavo). Natančnost vhodnih podatkov je ključnega pomena za izdelavo natančnih algoritmov. V resničnih aplikacijah pogosto ni tako, zato se običajno veliko časa in truda nameni zbiranju, čiščenju, urejanju, poenotenju, preverjanju napačnih vhodnih podatkov itd. Poleg natančnih podatkov je še en pomemben vidik značilnosti vhodnih podatkov njihova predstavitev in kodiranje. Različni načini kodiranja podatkov lahko razkrijejo različne značilnosti podatkov in znatno "pomagajo" modelom ML pri razkrivanju skritih vzorcev v podatkih. Tu vidimo Ahilovo peto algoritmov ML. Pogosto se preveč pozornosti posveča oblikovanju metod za pridobivanje informacij in inteligence iz podatkov (tj. samim algoritmom), premalo pozornosti pa se posveča vhodnim podatkom in njihovi povezavi z izhodnimi podatki. Na splošno se šteje za samoumevno, da so vhodni podatki vzročno povezani z izhodnimi podatki, kar pa včasih sploh ni tako. Zato mora biti naslednji velik korak pri razvoju ML iskanje boljših načinov za zbiranje, predstavitev in kodiranje podatkov.

Izhodni podatki predstavljajo meritve določenega problema, ki ga poskušamo rešiti. Pri klasifikacijskem problemu so to oznake razredov. Pri regresiji bo to realno število, ki ga poskušamo napovedati. V kontekstu specifičnega problema, pri problemih prepoznavanja govora, so lahko izhodni podatki človeško ustvarjeni prepisi zvočnih datotek. Pri težavah s prepoznavanjem slik so lahko izhodni podatki oznake razredov slik itd.

Stroškovna funkcija predstavlja način merjenja uspešnosti umetne inteligence in ML. Načeloma bi si želeli, da bi se odgovori algoritmov ujemali z izhodnimi podatki za dane vhodne podatke.



Stroškovna funkcija je tudi povratni signal za nabor parametrov, ki usmerjajo delo algoritma, tj. omogoča optimizacijo celotnega delovanja algoritma prek procesa učenja (iskanje optimalnega nabora parametrov). Proces učenja običajno vključuje nadzorovano učenje, pri katerem se model uči na označenih podatkih, da se s tehnikami, kot sta stohastično spuščanje po naklonu in povratno širjenje, čim bolj zmanjšajo napake pri napovedovanju. To modelu omogoča, da učinkovito prilagodi svoje notranje parametre, kar vodi do izboljšane učinkovitosti pri nalogah, kot sta odkrivanje in razvrščanje predmetov (LeCun, Bengio in Hinton, 2015).

10.3 Katera orodja se uporabljajo pri ML?

Na splošno lahko algoritme ML razdelimo v dve glavni kategoriji: nadzorovano in nenadzorovano učenje.

Pri nadzorovanem učenju se algoritmi usposabljaajo na naboru označenih podatkov, pri čemer se vsaka vhodna podatkovna točka poveže s pravilnim izhodnim podatkom. Ta jasna "slika" o tem, kakšen naj bi bil pravilen odgovor za določen vhodni podatek, omogoča algoritmu, da se nauči funkcije preslikave med vhodnimi podatki in izhodnimi podatki. V skladu s tem so tako vhodni kot izhodni podatki znani (Athanasopoulou et al., 2022). Pogoste aplikacije nadzorovanega učenja vključujejo naloge razvrščanja (npr. določanje, ali je elektronsko sporočilo neželena pošta ali ne) in naloge regresije (npr. napovedovanje cen hiš na podlagi različnih značilnosti). Nekateri izmed najbolj priljubljenih algoritmov, ki so se izkazali s številnimi aplikacijami, so posplošeni aditivni modeli, naključni gozdovi, boosting, klasifikacijska in regresijska drevesa, podporni vektorski stroji, razširjena linearna regresija, logistična regresija, k-najbližji sosedje, linearna diskriminantna analiza, lasso, nevronske mreže, prilagodljivi nevrofuzzy inferenčni sistem itd. (Rostami-Tabar & Mircetic, 2023). Nadzorovano učenje je učinkovito, saj za doseganje visoke natančnosti napovedi uporablja podatke, ki jih je ustvaril človek. Vendar je njegova učinkovitost močno odvisna od kakovosti in količine označenih podatkov.

Nasprotno pa nenadzorovano učenje obravnava nabore podatkov, ki nimajo označenih odgovorov. Zato algoritmi strojnega učenja brez nadzora uporabljajo neoznačene podatkovne nize, ki vključujejo samo vhodne podatke (Athanasopoulou et al., 2022). Pri tem so algoritmu na voljo samo vhodni podatki, njegov cilj pa je poiskati osnovne vzorce, strukture ali odnose v podatkih. Pogoste tehnike nenadzorovanega učenja vključujejo grozdenje (npr. združevanje strank po nakupnem vedenju) in zmanjševanje razsežnosti (npr. zmanjševanje števila spremenljivk v podatkovnem nizu, pri čemer se ohranijo pomembne informacije). Nenadzorovano učenje je



koristno za raziskovalno analizo podatkov in odkrivanje skritih struktur v podatkih. Pogosto se uporablja, kadar je označenih podatkov malo ali niso na voljo.

Druga pomembna kategorija, ki se razlikuje od nadzorovanega in nenadzorovanega učenja, je učenje z okrepitevami. Pri tem se algoritem uči z interakcijo z okoljem in prejemanjem povratnih informacij v obliki nagrad ali kazni. Tak pristop poskusov in napak omogoča algoritmu učenje optimalnih dejanj za maksimiranje kumulativnih nagrad. Učenje z okrepitevami se pogosto uporablja na področjih, kot so robotika, igranje iger in avtonomni sistemi.

Eden izmed najbolj priljubljenih in uspešnih algoritmov za ML izhaja iz veje nevronske mreže. Nevronske mreže obstajajo že od petdesetih let prejšnjega stoletja, vendar so postale priljubljene v osemdesetih letih prejšnjega stoletja in v zadnjih 12 letih. Zgrajene so na približno bioloških nevronov in načinu, kako si ti v možganih izmenjujejo delčke informacij, vendar razen tega med njimi ni pomembnih povezav. Danes se najpogosteje uporabljajo nevronske mreže v obliki globokega učenja, ki predstavljajo več skupkov skritih plasti med vhodnimi in izhodnimi značilnostmi, ki izvajajo več nelinearnih transformacij vhodnih značilnosti. Ker se je to izkazalo za zelo uspešno, je globoko učenje danes eno od najpomembnejših podpodročij ML (Chollet, 2021).

10.4 Študija primera

Ugotovitve Wenzla, Smita in Sardesaija (2019) o ML pri upravljanju oskrbovalne verige kažejo na vse večjo integracijo aplikacij ML v različne naloge oskrbovalne verige. Skladno s tem opazovana študija primera predstavlja uporabo AI & ML, ki se izvaja v osrednjem skladišču tovarne hrane (Mirčetić et al., 2016; Mircetic et al., 2014). V tovarniškem kompleksu je 30 viličarjev. Viličarji so vključeni v različne operacije znotraj kompleksa, ki so ključne za logistične operacije v proizvodnji, skladiščenju in odpremi izdelkov. Osrednje skladišče ima zmogljivost 11 100 paletnih mest in letno proizvodnjo od 300 000 do 350 000 palet. Trenutno tovarna oskrbuje približno 20 000 supermarketov z neposredno dostavo.

Problem vključevanja viličarjev je povezan z dejstvom, da prevelika ali premajhna vključenost viličarjev v različne tovarniške procese vodi v velike finančne in tržne izgube. Trenutno proces odločanja o tem, kje in kaj bo delal posamezen viličar, temelji na odločitvah strokovnjakov (vodij). Odločitve strokovnjakov temeljijo na njihovih izkušnjah brez pomoči sistema za podporo odločanju (DSS). Številni empirični dokazi kažejo, da človekova intuitivna presoja in odločanje pogosto nista optimalna, zlasti v pogojih kompleksnosti in stresa (Druzdzel in Flynn, 2002). To poudarja pomen vključevanja sistemov za podporo odločanju (DSS), ki strokovnjakom pomagajo pri odločanju.



V tej aplikaciji smo izbrali več algoritmov ML za pomoč pri optimizaciji delovanja nakladalnega skladišča. Algoritmi ML so zbrani v edinstvenem odločitvenem okviru, ki služi kot DSS za menedžerje in strokovnjake v določenem podjetju. Poleg tega lahko celoten DSS za odločanje opazujemo kot platformo umetne inteligence, saj nenehno preračunava predloge iz več modelov ML (koliko viličarjev uporabiti in katere) ter samodejno izbere najboljše glede na zagotovljene vhodne podatke operaterjev.

Opis težave

Postopek natovarjanja je ključnega pomena za logistiko v skladišču, saj vpliva na raven tržnih storitev. Med pošiljkami skladiščni strokovnjak določi število in izbor viličarjev za nakladanje, pri čemer ga vodijo trije dejavniki: (1) dokončanje nakladanja v določenem časovnem okviru, (2) zmanjšanje motenj pri drugih nalogah viličarjev in (3) uskladitev uporabe viličarjev z zmogljivostmi vzdrževanja, ki lahko hkrati opravijo dva generalna popravila. Vsak viličar opravi štiri do pet vzdrževalnih pregledov na leto.

Viličarji so bistveni za nakladanje, ki mora podpirati tržno strategijo podjetja in hkrati zagotavljati nemoteno izvajanje drugih dejavnosti. Napačna razporeditev viličarjev lahko privede do nezadostne uporabe virov ali škoduje ugledu podjetja in ravni storitev. Zamude pri nakladanju povzročajo kazni. Vodja mora uskladiti uporabo viličarjev v vseh dejavnostih, da bi se izognil hkratnim remontom in obvladal različne potrebe po vzdrževanju. Čeprav menedžerji običajno sprejemajo natančne odločitve, lahko v okoljih z visoko stopnjo stresa pride do napak. Zato je potreben DSS, ki bo povečal zanesljivost in zanesljivost odločanja.


AI in ML kot DSS za centralno skladišče

Prvi korak pri ustvarjanju sistemov AI in ML je pridobitev stabilnega in pravilnega vira znanja (podatkovne zbirke) ter osvetlitev poslovnih vlog, ki jih mora podpirati. Zato je na sliki 10.3 predstavljena metodologija za izgradnjo sistema DSS AI & ML.



Slika 10.3 Metodološki koraki za izgradnjo sistema AI & ML DSS (Rainer & Turban, 2008; Turban, Aronson, & Liang, 2005).

Znanje je bilo pridobljeno z razgovori z vodji, opazovanjem njihovih postopkov odločanja in pregledom skladiščnih evidenc. Za razvoj DSS za dani problem sta bili vzpostavljeni dve bazi znanja. Prva baza znanja vključuje odločitve o številu viličarjev, razporejenih na območju nakladanja (434 strokovnih odločitev), druga pa zajema, kateri viličarji so bili uporabljeni (368 strokovnih odločitev) v različnih operativnih scenarijih. V fazi sklepanja o znanju je bilo uporabljenih več algoritmov ML z uporabo programske opreme Matlab: Prilagodljiv nevrofuzzy inferenčni sistem (ANFIS), posplošeni aditivni modeli (GAM), naključni gozdovi, pospeševanje, klasifikacijska in regresijska drevesa (CART), razširjena linearna regresija, logistična regresija, k-najbližji sosedje (KNN) in linearna diskriminantna analiza (LDA). Ocenjeni so bili različni ML modeli in določeni so bili tisti z najboljšo učinkovitostjo. ANFIS in CART sta pokazala najboljše rezultate in bila izbrana kot končna DSS za praktično uporabo v podjetju. Prenos znanja je bil olajšan z uporabniškim vmesnikom končnih modelov DSS. Struktura in logika DSS je prikazana na sliki 10.4.



Slika 10.4 Gradbena struktura skladiščnega DSS, ki temelji na algoritmih AI in ML.


Okvir DSS je sestavljen iz vhodne plasti, ki jo sestavlja več ključnih dejavnikov, ki vplivajo na uporabo viličarjev. Sloj ML ima modele ML, ki preračunavajo predlog, koliko in katere viličarje je treba uporabiti v danem vhodnem scenariju. Najuspešnejši modeli so izbrani kot modeli ekspertnega sistema (ES modeli), saj je baza znanja, na podlagi katere so ustvarjeni ML modeli, pridobljena od strokovnjakov. Prvi model se osredotoča na določanje števila viličarjev, potrebnih na nakladalnem območju (model ES 1). Drugi model obravnava problem izbire, katere posebne viličarje je treba vključiti (model ES 2). Oba modela sta razvita z uporabo tehnik nadzorovanega strojnega učenja. Po navedbah Turbana, Aronsona in Lianga (2005) je strojno učenje pokazalo

odlične rezultate pri oblikovanju inteligentnih sistemov za podporo odločanju (DSS). Modela ES pošiljata signale (predloge in predloge ML) naprej v operacijo razvrščanja, pri čemer se lahko vsak viličar, ki je razvrščen v skupino razvrščanja "Da", vključi v določeno operacijo nakladanja.

Dejavniki, ki so vplivali na odločitve vodje, so bili ugotovljeni s posvetovanji. Pri določanju števila viličarjev, ki jih je treba namestiti na območju nakladanja, sta ključna dejavnika določen čas nakladanja (15 do 135 minut) in količina tovora (15 do 225 palet). Pri izbiri viličarjev, ki jih bo vključil, vodja upošteva pomembnost trenutne dejavnosti (v skladu s politiko podjetja je ocenjena od 1 do 9), stopnjo izkoriščenosti viličarja, njegovo oddaljenost od nakladalne rampe in povprečno stopnjo izkoriščenosti vseh viličarjev. Vsak viličar ima določeno število delovnih ur, preden je potreben remont, njegova uporaba pa je nad to mejo omejena. Izkoriščenost viličarja (FU) je odstotek delovnih ur, ki jih izkoristi posamezen viličar, medtem ko je povprečna izkoriščenost viličarja (AFU) povprečna izkoriščenost delovnih ur vseh viličarjev. Višja vrednost AFU pomeni, da bo večina viličarjev kmalu potrebovala remont.

Uporabniški vmesnik sistema DSS


V večini vhodnih situacij sta se najbolje izkazala ANFIS in CART. Zato sta bila izbrana kot motorja danega DSS in njegovih ES. Uporabniški vmesnik modela ES 1 je predstavljen na sliki 10.5 in operaterjem omogoča hitro in enostavno odločanje o številu viličarjev, ki jih je treba uporabiti, tako da preprosto premaknejo navpično črto skozi področje vhodnih spremenljivk na podlagi določenega časa nakladanja in količine tovora.



Slika 10.5 Fuzzy inferenčni sistem modela ES 1.



Model ES 2 služi kot dopolnilno orodje k modelu ES 1, saj izboljša sprejemanje odločitev z zagotavljanjem informacij o tem, ali je treba na nakladalnem območju uporabiti določen viličar (slika 10.6). Z upoštevanjem položaja viličarja (oddaljenost od območja nakladanja), njegove trenutne dejavnosti (pomembnost dejavnosti), izkoriščenosti delovnih ur (FU) in povprečne izkoriščenosti vseh viličarjev (AFU) lahko uporabniki enostavno ugotovijo, ali je določen viličar primeren za nakladanje ali je treba izbrati drugega. Odločitveno drevo CART je preprosto za razlago, saj ni treba vnašati vrednosti v programsko opremo. Namesto tega lahko drevo s slike 10.6 natisnete in ga za hitro sklicevanje postavite na vidno mesto v skladišču.



Slika 10.6 Odločitveno drevo modela ES 2 v zvezi z vključitvijo viličarja.

Upravljalci lahko vsakodnevno uporabljajo predstavljeni sistem DSS, kar pripomore k večji odzivnosti oskrbovalne verige na zahteve strank in zagotavlja visoko verjetnost pravočasne dobave. Predlagani DSS z umetno inteligenco in ML je pokazal uspešne rezultate pri pridobivanju znanja "know-how" strokovnjakov in zajemanju njihove "logike sklepanja". Z uporabo te metode je mogoče pridobiti strokovno znanje vodij in ga uporabiti pri drugih skladiščnih operacijah. To je še posebej dragoceno za praktike, saj je najemanje skladiščnih strokovnjakov pogosto drago. Poleg tega lahko DSS služi tudi kot orodje za usposabljanje vodij začetnikov, saj jim pomaga pridobivati izkušnje in sčasoma izboljšati njihove sposobnosti odločanja. Zato so sistemi umetne inteligence in ML, ki lahko simulirajo odločitve vodje, bistvena orodja, ki omogočajo znatne prihranke pri stroških in večjo učinkovitost skladiščnih operacij.



LITERATURA POGLAVJE 10

- 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>