



4. STROJNO UČENJE

Autor: Dejan Mirčetić

Mnogo je pitanja o tome što je strojno učenje (eng. *Machine Learning* - ML). Je li to doista proces u kojem strojevi sami uče od vanjskog okruženja ili je to formalizirani proces putem matematičkih algoritama koji omogućuju računalima da „shvate” pravila iz vanjskog svijeta? Koje alate koristi ML? Kako izgleda tipični tok podataka u ML cjevovodu? Je li ono primjenjivo na tradicionalne industrije, a ne samo na IT i industrije povezane s internetom? Gdje je mjesto ML-a u kontekstu poslovanja? Kako ga sustavno koristiti za rješavanje poslovnih problema? Postoji li arhitektura kako to primijeniti na opskrbne lance?

Na ova i slična pitanja pokušat će se dati odgovore u sljedećem poglavlju, a na kraju će se prikazati stvarne studije slučaja primjene ML algoritama u lancu opskrbe hranom.


4.1. Što je strojno učenje?

Strojno učenje je disciplina usmjerena na dva međusobno povezana pitanja: Kako se može konstruirati računalni sustav koji se automatski poboljšava kroz iskustvo? i Koji su temeljni statistički računalno-informacijsko-teorijski zakoni koji upravljaju svim sustavima učenja, uključujući računala, ljude i organizacije? Proučavanje strojnog učenja važno je za rješavanje ovih temeljnih znanstvenih i inženjerskih pitanja, ali i za vrlo praktičan računalni softver koji se koristi u mnogim aplikacijama (Jordan i Mitchell, 2015).

ML proizlazi iz ovog pitanja: može li računalo ići dalje od onoga "što znamo kako mu narediti da nešto izvrši" i samostalno naučiti kako izvršiti određeni zadatak?

Može li nas računalo iznenaditi? Umjesto da programeri ručno izrađuju pravila za obradu podataka, može li računalo automatski naučiti ta pravila gledajući podatke? Ovo pitanje otvara vrata novoj paradigmi programiranja (Chollet, 2021).

ML omogućuje temeljnu promjenu u paradigmi programiranja (slika 4.1). U klasičnom programiranju ljudski programer unosi pravila (program) i podatke koji se analiziraju i obrađuju u skladu s tim pravilima. Kao rezultat toga, odgovori se dobivaju kraju. S druge strane, kod ML-a ljudski programer unosi podatke s odgovorima koji se očekuju od podataka, i ishodom pravila.



Slika 4.1 Klasično programiranje vs. treniranje sustava pomoću ML-a

Izvor: Chollet (2021).

Klasično programiranje bi se moglo shvatiti kao imperativno programiranje budući da programer unaprijed definira sva pravila, a izvršavanje koda se izvodi u skladu s tim, dok bi se ML moglo shvatiti kao deklarativno programiranje gdje se izražavaju ciljevi više razine ili opisuju važna ograničenja, i oslanja se na matematičke algoritme za odluku kako i/ili kada to pretočiti u djelo.

Danas je ML temelj bezbrojnih važnih aplikacija, uključujući pretraživanje weba, zaštitu od neželjene pošte, prepoznavanje govora, preporuke proizvoda i još mnogo toga (Ng, 2017). Mnogi programeri sustava umjetne inteligencije sada prepoznaju da, za mnoge aplikacije, daleko lakše može biti uvježbati sustav pokazujući mu primjere željenog ulazno-izlaznog ponašanja, nego ga ručno programirati predviđanjem željenog odgovora za sve moguće ulaze. Učinak ML-a također se široko osjetio u računalnoj znanosti i u nizu industrija koje se bave problemima koji zahtijevaju veliki broj podataka, kao što su potrošačke usluge, dijagnoza grešaka u složenim sustavima i kontrola logističkih lanaca (Jordan i Mitchell, 2015).

4.2. Temelji i teorijske pretpostavke strojnog učenja

Pozadina ML-a leži u matematici, točnije statistici. Stoga ML koristi teorijsku pozadinu i algoritme razvijene u **statističkom učenju**, a također postoji rasprava je li ML stvarno



područje za sebe ili je samo dio statistike. U praksi, ML algoritmima obično nedostaje određena razina matematičke rigidnosti i ponekad lako prelaze neka matematička ograničenja prisutna u statistici. Na primjer, ML algoritmi ne obraćaju puno pozornosti na intervale pouzdanosti kada optimiziraju koeficijente u parametarskim algoritmima, iako je to jedna od najvažnijih tema u statistici. Općenito, **postoji veliko preklapanje ML-a i statistike**, a neki od najpoznatijih kreatora ML algoritama i profesora koji se njima bave tvrde da je to samo dio statistike (Hastie et al., 2009). Bez obzira je li zasebno područje ili dio statistike, ML se sastoji od nekoliko koraka u stjecanju znanja iz podataka. Ne postoji opći konsenzus o ovim koracima, ali općenito, oni se mogu predstaviti kao transformacija različitih izvora podataka u uvide poslovne inteligencije.

U poslovnom kontekstu, ML modeli su beskorisni ako nemaju odgovarajuću podršku u pogledu predobrade podataka, rudarenja podataka i primjene uvida u stvarne procese. Stoga izrada ML algoritama bez mogućnosti ažuriranja modela i korištenja njegovog izlaza za stvarni proces donošenja odluka ne donosi nikakvu vrijednost modernim tvrtkama. U skladu s tim, u suvremenoj poslovnoj analitici, kvantitativni ML proces obično je dio tijeka rada poslovne inteligencije. Točnije, dio je važnih potprocesa poslovne inteligencije (znanost o podacima i analitika podataka kao dio poslovne inteligencije). Pojedini o ulozi ML-a u tim procesima i samim stvarnim procesima generiranja vrijednosti za poslovanje putem ML-a bit će navedene u sljedećem potpoglavlju.


4.3. Poslovna inteligencija i ML u opskrbnom lancu

Poslovna inteligencija, u kontekstu opskrbnih lanaca, je proces donošenja zaključaka o promatranim procesima u opskrbnom lancu, na temelju modeliranja podataka iz tih procesa. Uglavnom se temelji na statistici, ali u obzir dolaze i druga matematička područja: operacijska istraživanja, linearna algebra, neizrazita logika (u slučaju kada su podaci oskudni ili nedostaju), numerička optimizacija, metaheuristika itd. Dodatno, nove disruptivne tehnologije također postaju važan aspekt za analizu podataka i donošenje zaključaka: **strojno učenje, umjetna inteligencija, digitalni blizanci, smartizacija, živi laboratoriji** itd.

Ne postoje stroge procedure o tome kako treba organizirati postupak poslovne inteligencije i rad ML-a, ali postoje neke korisne smjernice u praksi i literaturi koje su se pokazale uspješnim prilikom provođenja analize. Procedura za provođenje poslovne inteligencije također se razlikuje prema podrijetlu softvera koji se koristi za analizu. Na primjer, Microsoft nudi nekoliko alata putem svog kanala Microsoft Business Intelligence paketa koji obavljaju različite zadatke:




unos podataka, pohranu podataka, integraciju podataka, upravljanje podacima, obradu podataka, izvješćivanje, dijeljenje podataka i znanost o podacima (slika 4.2).



Slika 4.2 Arhitektura Microsoft business intelligence

Izvor: ScienceSoft (n.d.).

U određenoj arhitekturi ML procedure se primjenjuju samo na razini znanosti o podacima putem nekoliko alata: Azure ML usluge, ML studio i R Server za HDInsight. Opći postupak kako se analiza podataka u kontekstu ML-a izvodi u R Serveru prikazan je na slici 4.3.




Slika 4.3 Koraci za analizu podataka pomoću ML-a u R Serveru

Izvor: Wickham et al. (2023).

Kada se radi o ML-u, obično postoji **zabluda da se većina vremena i truda troši na stvaranje ML algoritama**. Stvarnost je potpuno suprotna, većina vremena obično se troši na natezanje s podacima i zadatke predobrade, a ne na proces modeliranja. Ponekad su svi



procesi prije samog procesa modeliranja puno izazovniji i zahtjevniji. Zbog toga nema dvojbi o tome kako ove korake treba izvesti. Slika 2.9 prikazuje primjer dobrog pristupa pretvaranju podataka u poslovne uvide i opće znanje. Postupak započinje korakom uvoza, koji je jedan od najvažnijih koraka u izgradnji ML modela, budući da bez uvoza podataka u softver nije moguće provesti bilo kakvu analizu. To obično znači da se uzimaju podaci pohranjeni u datoteci, bazi podataka ili programskom sučelju web aplikacije (API) i učitavaju se u podatkovni okvir u R (Wickham et al., 2023). Drugi korak se odnosi na pospremanje podataka, što je postupak jedinstven za R i odnosi se na transformaciju podataka u određeni oblik za daljnju analizu (svaki stupac je varijabla, a svaki red je podatkovni okvir promatranja). Sljedeći korak vezan je uz transformaciju podataka koja obično uključuje sužavanje skupa opažanja na poduzorak od interesa. Dodatno, može također uključivati stvaranje novih varijabli kao kombinacije nekoliko postojećih ili generiranje skupne statistike. Vizualizacija i modeliranje imaju različite, ali komplementarne uloge u području analize podataka. Vizualizacija je aktivnost koja je duboko usmjerena na čovjeka i nudi uvide koji mogu promaknuti formaliziranim pristupima. Dobro kreirana vizualizacija može otkriti neočekivane uzorke, potaknuti nove upite i čak sugerirati da izvorna pitanja možda trebaju doradu ili drugačije podatke. Nasuprot tome, modeli pružaju matematički ili računalni okvir za odgovore na precizno formulirana pitanja. Nude skalabilnost i učinkovitost, što ih čini prikladnima za rukovanje velikim skupovima podataka. Međutim, modeli (u koje je također uključeno i ML) dolaze s inherentnim pretpostavkama i ne mogu dovesti u pitanje ili osporiti te pretpostavke. Posljedično, modeli možda neće imati mogućnost iznenaditi ili razotkriti nepredviđene uvide. Sinergija između vizualizacije i modeliranja očita je u njihovoj zajedničkoj ulozi u analizi podataka. Vizualizacija pomaže u početnom istraživanju, potičući formuliranje preciznih pitanja, dok modeli sustavno daju odgovore unutar definiranih parametara. Prepoznavanje snaga i ograničenja svakog pristupa je ključno, što vodi do sveobuhvatnijeg i informiranijeg procesa analize podataka. Posljednji korak predstavlja komunikaciju koja je ključna za uspjeh analize podataka jer ako se informacija ne dostavi donositelju odluka na pravi i dosljedan način, onda bi cijela analitika mogla biti uzaludna. Ključni element u analitici podataka su ML modeli, bez kojih se ne bi mogli donositi zaključci o poslovnim procesima. Kako bi se uhvatili u koštac sa specifičnim problemima opskrbnog lanca, arhitektura za aplikacije poslovne inteligencije opće namjene (predstavljene na slici 4.2) mora biti bolje podešena, kao i ML modeli. U skladu s tim, kako bi transformirala način na koji lanci opskrbe funkcioniraju povećanjem operativne učinkovitosti, poboljšanjem donošenja odluka i usmjeravanjem prema postizanju korporativnih ciljeva, tvrtka Equilibrium AI razvila je AI & ML platformu prikazanu na slici 4.4.



Slika 4.4 Cjevovod ML podataka i znanja za tvrtku Equilibrium AI

Izvor: Equilibrium AI (n.d.).

Slika predstavlja dobar primjer svakodnevne prakse kako se ekstrakcija znanja i uvida generira u aplikacijama vezanim uz opskrbni lanac. Općenito, proces se sastoji od backend i frontend operacija kako bi se stvorila vrijednost (poslovni uvidi) za korisnike. Pozadinski proces počinje izdvajanjem podataka iz različitih izvora podataka koji se obično nalaze u opskrbnim lancima:

- Baze podataka;
- Sustavi za planiranje resursa poduzeća (SAP, Navigator, Microsoft Dynamics, itd.);
- Aplikacije (web API);
- Flat datoteke (csv, xlsx, JSON, itd.);
- Web, internet i drugi mrežni izvori.

Svaki od izvora podataka ima drugačiju strukturu, protokole i sukladno tome postupke za to kako se podaci ekstrahiraju i učitavaju za čišćenje i pretprocesiranje prije primjene ML algoritama. Sukladno tome, ovaj se proces odvija preko tzv. *data loadera* koji imaju unaprijed programiran kod za rudarenje različitih izvora podataka i prijenos redova podataka u novu bazu podataka, koja je strukturirana i uređena za primjenu ML modela. Prije primjene ML modela, postoji jedan dodatni korak koji se zove pretprocesiranje podataka. U ovom koraku u retku podataka prikupljenih od tvrtki provjeravaju se pogrešni ulazi, nelogičke vrijednosti, ispravna struktura ulaza, outlieri, dvostruki unosi, NA, NaN, itd. Postupak se nastavlja



spajanjem vanjskih podataka s podacima tvrtke. Ti su podaci obično povezani s vanjskim čimbenicima koji mogu potencijalno utjecati na promatrani poslovni proces opskrbnog lanca, na primjer, vremenski podaci, indeks potrošačkih cijena, prosječni dohodak u određenoj regiji, specifične demografske karakteristike u određenom području, cijene plina, izbijanja pandemije, komentari na društvenim mrežama o proizvodima tvrtke itd. Ovo je vrlo važno jer holistički prikuplja sve moguće čimbenike (unutarnje i vanjske) koji mogu utjecati na određeni poslovni proces, čime se povećava šansa da će ML modeli pronaći pravi signal u podacima i moći donijeti ispravan zaključak i pravila koji su glavni uzroci razlozi zašto se poslovni proces ponaša kao što je opaženo.

Nakon spajanja unutarnjih i vanjskih podataka, pretprocesiranje se sastoji od otkrivanja signala, uklanjanja grešaka iz podataka, inženjeringa značajki i nasumične podjele podataka skup za treniranje i testiranje (ponekad na validacijske podatke ako se razvija model neuronske mreže). Podaci koji izlaze iz koraka pretprocesiranja čiste se i strukturiraju za primjenu ML modela.

Izlazni dio sastoji se od vizualizacije podataka, razvoja ML & AI i dijeljenja podataka. Ponekad se ti podaci dijele bez primjene ML modela na druge platforme koje provode različite vrste analiza (samo izvješćivanje dionika ili vladinih agencija). Proces vizualizacije izvodi se preko frontend dijela platforme koji je usmjeren na korisnika i omogućuje korisnicima da postavljaju zahtjeve o tome koje podatke, kako i u kojim postavkama žele vidjeti promatrane podatke (na primjer slika 4.5).



Equilibrium AI




Slika 4.5 Tipični dio vizualizacije ML platforme u opskrbnim lancima

Izvor: Autor.



S druge strane, ML dio obrade podataka skriven je od očiju korisnika i nije ga lako razumjeti. Zbog toga se ML modeli ponekad smatraju modelima **crne kutije** u kojima ne postoji jasno razumijevanje kako je stroj točno povezao promatrani ulaz s promatranim izlazom. To je jedna od prepreka koja onemogućuje širu upotrebu ML modela u praksi, posebno onih koji su složeni za tumačenje (Rostami-Tabar i Mircetic, 2023). Sukladno tome, mogli bismo podijeliti ML modele na one s visokom interpretabilnošću - niskom fleksibilnošću i s niskom interpretabilnošću - većom fleksibilnošću (slika 4.6). Općenito, kako se fleksibilnost ML metode povećava, točnost ML modela se obično povećava, a interpretabilnost smanjuje (Mirčetić et al., 2016).



Slika 4.6 Prikaz kompromisa između fleksibilnosti i interpretabilnosti, korištenjem različitih ML metoda


Izvor: Hastie et al. (2009).

4.3.1. ML i poslovni podaci iz opskrbnog lanca

Ako korisnici bolje razumiju vizualizaciju i grafiku kao što je slika 4.5, zašto nam uopće treba ML i možemo li preskočiti modeliranje podataka pomoću ML-a i samo napraviti informativnu grafiku? Nažalost ne. Možda je glavni razlog zašto su nam potrebni ML modeli taj što nije moguće u svim situacijama imati lako čitljive i detektabilne uzorke u podacima koji se vide putem grafike (kao na slici 4.5). Češća je situacija da grafika obično ne može otkriti misterij onoga što se događa u promatranim poslovnim podacima i potrebni su nam jači alati u obliku



ML algoritama za dublje kopanje u podatke i traženje **pravila za generiranje podataka** (slika 4.7) .



Slika 4.7 Statističke karakteristike proizvoda u lancu opskrbe hranom (sažeto za sve proizvode)

Izvor: Autor

Vrlo je teško donijeti lake zaključke iz slike 4.7 i izvesti poslovna pravila o procesu generiranja podataka. Kako bismo pronašli uzorke u podacima sa slike, razvili smo ML model koji bi se mogao koristiti za sažimanje karakteristika i otkrivanje važnih signala u podacima. U skladu s tim, razvijeni ML model za lanac opskrbe hranom predstavljen je u jednadžbi 1. Osnovni pokretač i okosnica ovog ML modela je autoregresivni integrirani model pomičnog prosjeka, sa sljedećim općim oblikom:

$$y_t = c + (\phi_1 y_{t-1}^* + \dots + \phi_p y_{t-p}^*) + (\theta_1 e_{t-1} + \dots + \theta_q e_{t-q}) + e_t; \quad (1)$$

$$y_t - y_{t-1} = c + \phi_1 (y_{t-1} - y_{t-2}) + \dots + \phi_p (y_{t-p} - y_{t-p-1}) + (\theta_1 B e_t + \dots + \underbrace{\theta_q e_{t-q}}_{\theta_q B^q e_t});$$

$$y_t - B y_t = c + \phi_1 (y_{t-1} - B y_{t-1}) + \dots + \phi_p (y_{t-p} - B y_{t-p}) + (e_t (1 + \theta_1 B + \dots + \theta_q B^q));$$

$$(1 - B) y_t = c + \phi_1 (1 - B) y_{t-1} + \dots + \phi_p (1 - B) y_{t-p} + e_t (1 + \theta_1 B + \dots + \theta_q B^q);$$

$$(1 - B) y_t = c + \phi_1 (1 - B) B y_t + \dots + \phi_p (1 - B) B^p y_t + e_t (1 + \theta_1 B + \dots + \theta_q B^q);$$

$$\underbrace{(1 - B)^d y_t}_{\text{differencing}} \cdot \underbrace{(1 - \phi_1 B - \dots - \phi_p B^p)}_{AR(p)} = c + \underbrace{e_t (1 + \theta_1 B + \dots + \theta_q B^q)}_{MA(q)}.$$



ML model jasno pokazuje svoju nisku interpretabilnost i karakteristike crne kutije. Prosječnom poslovnom korisniku teško je razumjeti veze između ulaznih i izlaznih podataka. Štoviše, prosječnom poslovnom korisniku kada se suoči s predstavljanim modelom nameće se pitanje! Što je jednažba (1)? Mogli bismo tvrditi da jednažba (1) predstavlja pravila sa slike 4.1, generirana cjevovodom ML podataka i znanja, koji otkriva misterij o procesima generiranja podataka u danom SC poslovnom okruženju.

Na prvi pogled, čini se da razvijeni ML model u jednažbi (1) ne poboljšava naše razumijevanje podataka. Još uvijek smo zbunjeni kao sa slikom 4.7, ali ML model ima ključnu prednost u odnosu na sliku. U biti, ML model je **matematička formula** koja možda nije lako razumljiva ljudskom korisniku, ali je potpuno razumljiva računalu, koje **se može programirati da koristi zadanu formulu** i donosi **poslovne odluke** na temelju otkrivenih pravila.

REFERENCE

1. Chollet, F. (2021). Deep learning with Python. Simon and Schuster.
2. Equilibrium AI (n.d.). Equilibrium AI Data Pipeline [available: <https://eqains.com/>, pristupljeno: January 23, 2024]
3. Hastie, T., Tibshirani, R., Friedman, J. H., & Friedman, J. H. (2009). The elements of statistical learning: Data mining, inference, and prediction (Vol. 2). Springer.
4. Jordan, M. I. & Mitchell, T. M. (2015). Machine learning: Trends, perspectives, and prospects. Science, 349(6245), pp. 255-260.
5. 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), pp. 393-401.
6. Ng, A. (2017). Machine learning yearning. [available: <http://www.mlyearning.org/>, pristupljeno: January 23, 2024]
7. Rostami-Tabar, B. & Mircetic, D. (2023). Exploring the association between time series features and forecasting by temporal aggregation using machine learning. Neurocomputing, 548, 126376.
8. ScienceSoft (n.d.). Microsoft Business Intelligence to Drive Robust Analytics and Insightful Reporting [available: <https://www.scnsoft.com/services/business-intelligence/microsoft>, pristupljeno: January 23, 2024]



9. Wickham, H., Çetinkaya-Rundel, M. & Grolemund, G. (2023). R for data science. O'Reilly Media, Inc.