



4. MAŠINSKO UČENJE

Autor: Dejan Mirčetić

Mnogo je pitanja o tome šta je mašinsko učenje (eng. *Machine Learning* - ML). Da li je to zaista proces u kojem mašine same uče od spoljnog okruženja ili je to formalizovani proces koji putem matematičkih algoritama omogućava računarima da „shvate” pravila iz spoljnog sveta? Koje alate koristi ML? Kako izgleda tipični tok podataka u ML cevovodu? Je li ono primjenjivo na tradicionalne industrije, a ne samo na IT i industrije povezane s internetom? Gde je mesto ML-a u kontekstu poslovanja? Kako ga sistematski koristiti za rešavanje poslovnih problema? Postoji li arhitektura kako to primeniti na lance snabdevanja?


Na ova i slična pitanja pokušaće se dati odgovore u sledećem poglavlju, a na kraju će se prikazati stvarne studije slučaja primene ML algoritama u lancu snabdevanja hranom.

4.1. Šta je mašinsko učenje?

Mašinsko učenje je disciplina usmerena na dva međusobno povezana pitanja: Kako se može konstruisati računarski sistem koji se automatski poboljšava kroz iskustvo? i Koji su osnovni statistički računarsko-informaciono-teorijski zakoni koji upravljaju svim sistemima učenja, uključujući računare, ljude i organizacije? Proučavanje mašinskog učenja važno je za rešavanje ovih osnovnih naučnih i inženjerskih pitanja, ali i za vrlo praktičan računarski softver koji se koristi u mnogim aplikacijama (Jordan i Mitchell, 2015).

ML proizlazi iz ovog pitanja: može li računar ići dalje od onoga "što znamo kako mu narediti da nešto izvrši" i samostalno naučiti kako izvršiti određeni zadatak? Može li nas računar iznenaditi? Umesto da programeri ručno izrađuju pravila za obradu podataka, može li računar automatski naučiti ta pravila posmatrajući podatke? Ovo pitanje otvara vrata novoj paradigmi programiranja (Chollet, 2021).

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



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

Izvor: Chollet (2021).

Klasično programiranje bi se moglo shvatiti kao imperativno programiranje budući da programer unapred definiše sva pravila i izvršavanja koja se izvode u skladu s tim, dok se ML može shvatiti kao deklarativno programiranje gde se izražavaju ciljevi višeg nivoa ili opisuju važna ograničenja, i oslanja se na matematičke algoritme za odluku kako i/ili kada to pretočiti u delo.

Danas je ML baza bezbrojnih važnih aplikacija, uključujući pretraživanje weba, zaštitu od neželjene pošte, prepoznavanje govora, preporuke proizvoda i još mnogo toga (Ng, 2017). Mnogi programeri sistema veštačke inteligencije sada prepoznaju da se, za mnoge aplikacije, daleko lakše može uvežbati sistem pokazujući mu primere željenog ulazno-izlaznog ponašanja, nego ga ručno programirati predviđanjem željenog odgovora za sve moguće ulaze. Učinak ML-a takođe se široko osetio u računarskoj nauci i u nizu industrija koje se bave problemima koji zahtijevaju veliki broj podataka, kao što su potrošačke usluge, dijagnoza grešaka u složenim sistemima i kontrola logističkih lanaca (Jordan i Mitchell, 2015).

4.2. Temelji i teorijske pretpostavke mašinskog učenja

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



područje za sebe ili je samo deo statistike. U praksi, ML algoritmima obično nedostaje određeni nivo matematičke rigidnosti i ponekad lako prelaze neka matematička ograničenja prisutna u statistici. Na primer, ML algoritmi ne obraćaju puno pažnje na intervale pouzdanosti kada optimiziraju koeficijente u parametarskim algoritmima, iako je to jedna od najvažnijih tema u statistici. Generalno, **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 deo statistike (Hastie et al., 2009). Bez obzira da li je zasebno područje ili deo statistike, ML se sastoji od nekoliko koraka u sticanju znanja iz podataka. O ovim koracima, ne postoji opšti konsenzus ali generalno, 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 primene uvida u stvarne procese. Stoga izrada ML algoritama bez mogućnosti ažuriranja modela i korišćenja njegovog izlaza za stvarni proces donošenja odluka ne donosi nikakvu vrednost modernim kompanijama. U skladu s tim, u savremenoj poslovnoj analitici, kvantitativni ML proces obično je deo toka rada poslovne inteligencije. Tačnije, deo je važnih potprocesa poslovne inteligencije (nauka o podacima i analitika podataka kao deo poslovne inteligencije). Pojediniosti o ulozi ML-a u tim procesima i samim stvarnim procesima generišu vrednosti za poslovanje putem ML-a biće navedene u sledećem potpoglavlju.


4.3. Poslovna inteligencija i ML u lancu snabdevanja

Poslovna inteligencija, u kontekstu lanaca snabdevanja, je proces donošenja zaključaka o promatranim procesima u lancu snabdevanja, na bazi modeliranja podataka iz tih procesa. Uglavnom se zasniva na statistici, ali u obzir dolaze i druga matematička područja: operaciona istraživanja, linearna algebra, fazi logika (u slučaju kada su podaci oskudni ili nedostaju), numerička optimizacija, metaheuristika itd. Dodatno, nove disruptivne tehnologije takođe postaju važan aspekt za analizu podataka i donošenje zaključaka: **mašinsko učenje, veštačka inteligencija, digitalni blizanci, smartizacija, živa laboratorija** itd.

Ne postoje stroge procedure o tome kako treba organizovati postupak poslovne inteligencije i rad ML-a, ali postoje neke korisne smernice u praksi i literaturi koje su se pokazale uspešnim prilikom sprovođenja analize. Procedura za sprovođenje poslovne inteligencije takođe se razlikuje prema poreklu softvera koji se koristi za analizu. Na primer, Microsoft nudi nekoliko alata putem svog kanala Microsoft Business Intelligence paketa koji obavljaju različite zadatke:




unos podataka, skladištenje podataka, integraciju podataka, upravljanje podacima, obradu podataka, izveštavanje, deljenje podataka i nauka 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 nivou nauke o podacima putem nekoliko alata: Azure ML usluge, ML studio i R Server za HDInsight. Opšti postupak analize podataka u kontekstu ML-a koji se 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 pre samog procesa modeliranja puno izazovniji i zahtevniji. Zbog toga nema dileme o tome kako ove korake treba izvesti. Slika 2.9 prikazuje primer dobrog pristupa transformisanju podataka u poslovne uvide i opšte znanje. Postupak započinje korakom uvoza, koji je jedan od najvažnijih koraka u izgradnji ML modela, budući da bez uvoza podataka u softver nije moguće sprovesti bilo kakvu analizu. To obično znači da se uzimaju podaci pohranjeni u datoteci, bazi podataka ili programskom interfejsu web aplikacije (API) i učitavaju se u R softver (Wickham et al., 2023). Drugi korak se odnosi na sređivanje podataka, što je postupak jedinstven za R i odnosi se na transformaciju podataka u određeni oblik za dalju analizu (svaka kolona je varijabla, a svaki red je jedna opservacija posmatranja). Sledeći korak vezan je uz transformaciju podataka koja obično uključuje sužavanje skupa opažanja na poduzorak od interesa. Dodatno, može takođe uključivati stvaranje novih varijabli kao kombinacije nekoliko postojećih ili generisanja zajedničke statistike. Vizualizacija i modeliranje imaju različite, ali komplementarne uloge u području analize podataka. Vizualizacija je aktivnost koja je duboko usmerena na čoveka i nudi napredne prikaze zasnovane na formalizovanim pristupima. Dobro kreirana vizualizacija može otkriti neočekivane uzorke, pokrenuti nova pitanja i čak sugerisati da izvorna pitanja možda trebaju doradu ili drugačije podatke. Nasuprot tome, modeli pružaju matematički ili računarski okvir za odgovore na precizno formulisana pitanja. Nude skalabilnost i učinkovitost, što ih čini prikladnima za rukovanje velikim skupovima podataka. Međutim, modeli (u koje je takođe uključen i ML) dolaze s inherentnim pretpostavkama i ne mogu dovesti u pitanje ili osporiti te pretpostavke. Posledično, modeli možda neće imati mogućnost da razotkriju nepredviđene uvide. Sinergija između vizualizacije i modeliranja očita je u njihovoj zajedničkoj ulozi u analizi podataka. Vizualizacija pomaže u početnom istraživanju, podstičući formulaciju preciznih pitanja, dok modeli sistemski daju odgovore unutar definisanih parametara. Prepoznavanje snaga i ograničenja svakog pristupa je ključno, što vodi do sveobuhvatnijeg i informisanijeg procesa analize podataka. Poslednji korak predstavlja komunikaciju koja je ključna za uspeh analize podataka jer ako se informacija ne dostavi donosiocu odluka na pravi i dosledan način, onda bi cela 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 lanca snabdevanja, arhitektura za aplikacije poslovne inteligencije opšte namene (predstavljene na slici 4.2) mora biti bolje podešena, kao i ML modeli. U skladu s tim, kako bi transformisala način na koji lanci snabdevanja funkcionišu povećanjem operativne učinkovitosti, poboljšanjem



donošenja odluka i usmeravanjem prema postizanju korporativnih ciljeva, kompanija Equilibrium AI razvila je AI & ML platformu prikazanu na slici 4.4.



Slika 4.4 Protok ML podataka i znanja za kompaniju Equilibrium AI

Izvor: Equilibrium AI (n.d.).

Slika predstavlja dobar primer svakodnevne prakse kako se ekstrakcija znanja i uvida generiše u aplikacijama vezanim za lanac snabdevanja. Generalno, proces se sastoji od backend i frontend operacija kako bi se stvorila vrednost (poslovni uvidi) za korisnike. Pozadinski proces počinje izdvajanjem podataka iz različitih izvora podataka koji se obično nalaze u lancima snabdevanja:

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

Svaki od izvora podataka ima drugačiju strukturu, protokole i u skladu sa tim, postupke kako se podaci ekstrahuju i učitavaju za čišćenje i pretprocesiranje pre primene ML algoritama. Shodno tome, ovaj se proces odvija preko tzv. *data loadera* koji imaju unapred programiran kod za rudarenje različitih izvora podataka i prenos redova podataka u novu bazu podataka, koja je strukturirana i uređena za primenu ML modela. Pre primene ML modela, postoji jedan



dodatni korak koji se zove pretprocesiranje podataka. U ovom koraku u liniji podataka prikupljenih od kompanije proveravaju se pogrešni ulazi, nelogičke vrednosti, ispravna struktura ulaza, outliers, dvostruki unosi, NA, NaN, itd. Postupak se nastavlja spajanjem spoljnih podataka s podacima kompanije. Ti su podaci obično povezani sa spoljnim faktorima koji mogu potencijalno uticati na posmatrani poslovni proces lanca snabdevanja, na primer, vremenski podaci, indeks potrošačkih cena, prosečni dohodak u određenom regionu, specifične demografske karakteristike u određenom području, cene plina, izbijanja pandemije, komentari na društvenim mrežama o proizvodima kompanije itd. Ovo je vrlo važno jer holistički prikuplja sve moguće faktore (unutrašnje i spoljne) koji mogu uticati na određeni poslovni proces, čime se povećava šansa da će ML modeli pronaći pravi signal u podacima i moći doneti ispravan zaključak i pravila o glavnim uzrocima i razlozima zašto se poslovni proces ponaša kao što je opaženo.

Nakon spajanja unutrašnjih i spoljnih podataka, pretprocesiranje se sastoji od otkrivanja signala, uklanjanja grešaka iz podataka, inženjeringa karakteristika i slučajne podele skupa podataka za treniranje i testiranje (ponekad na validacione podatke ako se razvija model neuronske mreže). Podaci koji izlaze iz koraka pretprocesiranja čiste se i strukturiraju za primenu ML modela.

Izlazni deo sastoji se od vizualizacije podataka, razvoja ML & AI i deljenja podataka. Ponekad se ti podaci dele bez primene ML modela na druge platforme koje sprovode različite vrste analiza (samo izveštavanje zainteresovanih ili vladinih agencija). Proces vizualizacije izvodi se preko frontend dela platforme koji je usmeren na korisnika i omogućava korisnicima da postavljaju zahteve o tome koje podatke, kako i u kojim postavkama žele videti posmatrane podatke (na primer slika 4.5).




Equilibrium AI



Slika 4.5 Tipični deo vizualizacije ML platforme u lancima snabdevanja

Izvor: autor Dejan Mirčetić

S druge strane, ML deo obrade podataka skriven je od očiju korisnika i nije ga lako razumeti. Zbog toga se ML modeli ponekad smatraju modelima **crne kutije** u kojima ne postoji jasno razumevanje kako je uređaj tačno povezao posmatrani ulaz s posmatranim 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). Shodno tome, ML modeli mogu se podeliti na one s visokom interpretabilnošću - niskom fleksibilnošću i s niskom interpretabilnošću - većom fleksibilnošću (slika 4.6). Generalno, kako se fleksibilnost ML metode povećava, tačnost ML modela se obično povećava, a interpretabilnost smanjuje (Mirčetić et al., 2016).




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

Izvor: Hastie et al. (2009).

ML i poslovni podaci iz opskrbnog lanca

Ako korisnici bolje razumeju vizualizaciju i grafiku kao što je slika 4.5, zašto je uopšte potreban ML i može li se preskočiti modeliranje podataka pomoću ML-a i samo napraviti informativna grafika? Na žalost 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 misteriju onoga što se događa u posmatranim poslovnim podacima i potrebni su nam jači alati u obliku ML algoritama za dublje kopanje u podatke i traženje **pravila za generisanje podataka** (slika 4.7) .



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

Izvor: autor Dejan Mirčetić

Vrlo je teško doneti lake zaključke iz slike 4.7 i izvesti poslovna pravila o procesu generisanja podataka. Kako bi pronašli uzorke u podacima sa slike, razvijen je 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 snabdevanja hranom predstavljen je u jednačini 1. Osnovni pokretač i okosnica ovog ML modela je autoregresivni integrisani model pokretnog proseka, sa sledećim opštim oblikom:

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

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

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

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

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

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

ML model jasno pokazuje svoju nisku interpretabilnost i karakteristike crne kutije. Prosečnom poslovnom korisniku teško je razumeti veze između ulaznih i izlaznih podataka. Štaviše,



prosečnom poslovnom korisniku kada se suoči s predstavljenim modelom nameće se pitanje! Šta je jednačina (1)? Mogli bismo tvrditi da jednačina (1) predstavlja pravila sa slike 4.1, generisana tokom ML podataka i znanja, koji otkriva misteriju o procesima generisanja podataka u datom SC poslovnom okruženju.

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

LITERATURA

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. & Golemund, G. (2023). R for data science. O'Reilly Media, Inc.