

Analiza IoT podataka

Sadržaj

- Uvod
- Mašinsko učenje
- Big data tehnologije analize
- Analiza edge streaming aplikacija
- Mrežna analiza

Uvod

- ❑ U IoT svijetu stvaranje ogromne količine podataka iz senzora je uobičajeno i jedan od najvećih izazova - ne samo iz perspektive transporta, već i sa stanovišta upravljanja podacima.
- ❑ Primjer ogromne količine podataka koje može generisati IoT nalazi se u industriji komercijalnog vazduhoplovstva i sensorima koji su raspoređeni u cijelom avionu.
- ❑ Moderni mlazni motori opremljeni su hiljadama senzora koji generišu preko 10 GB podataka u sekundi.
- ❑ Jedan avionski motor može biti opremljen sa oko 5000 senzora.
- ❑ Dvomotorni komercijalni avion sa ovakvim motorima koji rade u prosjeku 8 sati dnevno generiše preko 500 TB podataka dnevno.
- ❑ Avioni danas imaju hiljade drugih senzora povezanih na trup aviona i druge sisteme.
- ❑ Jedno krilo modernog džambo džeta opremljeno je sa 10.000 senzora.
- ❑ Potencijal za petabajt (PB) podataka po danu po komercijalnom avionu nije pretjeran - i to je samo za jedan avion.
- ❑ Širom svijeta ima oko 100.000 komercijalnih letova dnevno pa je količina IoT podataka koja dolazi samo iz komercijalnih avio-kompanija je ogromna.

Uvod

Strukturirani i nestrukturirani podaci

- ❑ Strukturirani podaci slijede model ili šemu koja definiše kako su podaci predstavljeni ili organizovani, što znači da se dobro uklapaju u tradicionalni sistem upravljanja relacionim bazama podataka.
- ❑ Strukturirani podaci mogu biti u jednostavnom tabelarnom obliku.
- ❑ Strukturirani podaci se nalaze u većini računarskih sistema i uključuju sve, od bankarskih transakcija i faktura do računarskih log fajlova i konfiguracija rutera.
- ❑ Podaci IoT senzora često koriste strukturirane vrijednosti, kao što su temperatura, pritisak, vlažnost,..., koje se sve šalju u poznatom formatu.
- ❑ Strukturirani podaci se lako formatiraju, memorišu, pretražuju i obrađuju.
- ❑ Širok spektar alata za analizu podataka je lako dostupan za obradu ove vrste podataka (od odgovarajućih skripti do komercijalnog softvera kao što je Microsoft Excel).



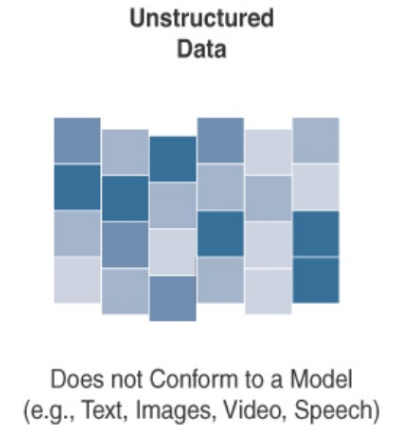
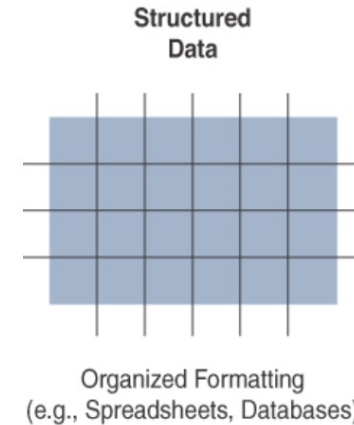
David Hanes, et al, "IoT Fundamentals: Networking Technologies, Protocols, and Use Cases for the Internet of Things", Cisco Press, 2017, SAD

Uvod

Strukturirani i nestrukturirani podaci

❑ Nestrukturiranim podacima nedostaje logička šema za razumijevanje i dekodiranje podataka tradicionalnim programskim sredstvima.

- ❑ Primjeri ovog tipa podataka uključuju tekst, govor, slike i video.
- ❑ Kao opšte pravilo, svi podaci koji se ne uklapaju uredno u unaprijed definisani model podataka klasifikuju se kao nestrukturirani podaci.
- ❑ Prema nekim procjenama, oko 80% poslovnih podataka je nestrukturirano.
- ❑ Zbog ove činjenice, veliku pažnju privlače metode analize podataka koje se mogu primijeniti na nestrukturirane podatke, kao što su kognitivno računarstvo i mašinsko učenje.
- ❑ Pomoću aplikacija za mašinsko učenje, kao što je *Natural Language Processing (NLP)*, može se dekodirati govor.
- ❑ Sa aplikacijama za prepoznavanje slika/lice, mogu se izdvojiti kritične informacije sa fotografija i video zapisa.

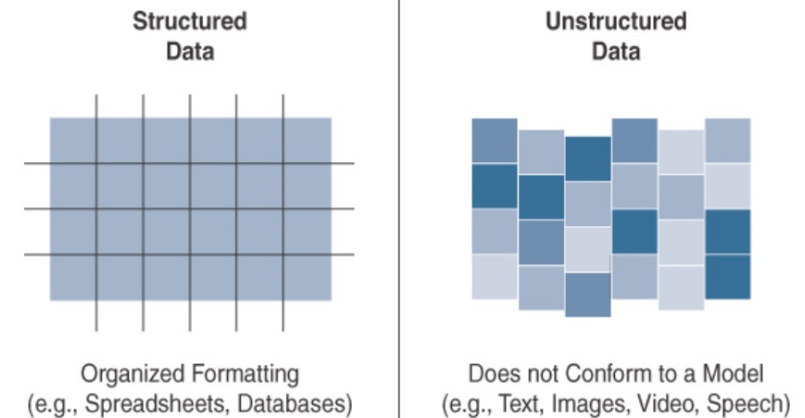


David Hanes, et al, "IoT Fundamentals: Networking Technologies, Protocols, and Use Cases for the Internet of Things", Cisco Press, 2017, SAD

Uvod

Strukturirani i nestrukturirani podaci

- ❑ Treća klasifikacija podataka, polustrukturirani podaci, ponekad se uključuje zajedno sa strukturiranim i nestrukturiranim podacima.
- ❑ Polustrukturirani podaci su hibrid strukturiranih i nestrukturiranih podataka i imaju karakteristike oba tipa podataka.
- ❑ Iako nisu relacioni, polustrukturirani podaci sadrže određenu šemu i konzistentnost.
- ❑ E-mail je dobar primjer polustrukturiranih podataka jer su polja definisana, ali sadržaj u poljima poruke i priložima je nestrukturiran.
- ❑ Drugi primjeri uključuju JavaScript notaciju objekata (JSON) i Extensible Markup Language (XML), koji su uobičajeni formati za razmjenu podataka koji se koriste na webu i u nekim razmjenama IoT podataka.

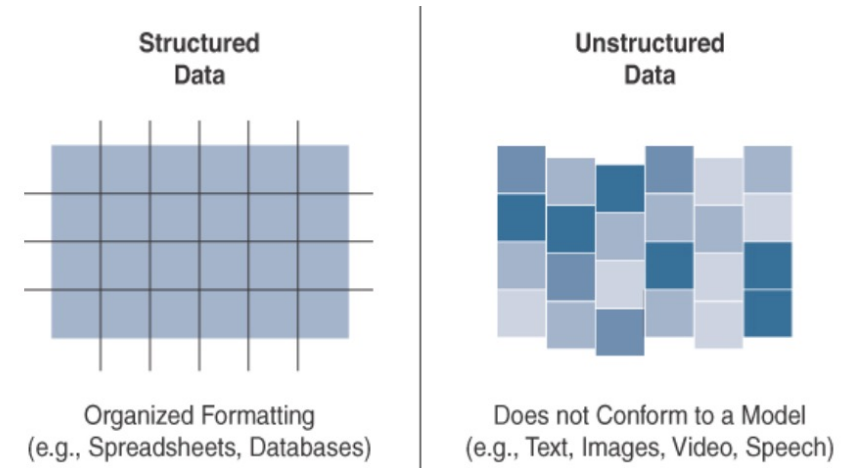


David Hanes, et al, "IoT Fundamentals: Networking Technologies, Protocols, and Use Cases for the Internet of Things", Cisco Press, 2017, SAD

Uvod

Strukturirani i nestrukturirani podaci

- ❑ Pametni objekti u IoT mrežama generišu i strukturirane i nestrukturirane podatke.
- ❑ Strukturiranim podacima se lakše upravlja i obrađuje.
- ❑ Sa druge strane, nestrukturirani podaci obično zahtijevaju različite analitičke alate za obradu podataka.
- ❑ Poznavanje obje klase podataka je važno jer poznavanje klasa podataka čini integraciju s odgovarajućim rješenjem za analizu podataka mnogo lakšom.



David Hanes, et al, "IoT Fundamentals: Networking Technologies, Protocols, and Use Cases for the Internet of Things", Cisco Press, 2017, SAD

Uvod

Kretanje podataka

- ❑ Kao i u većini mreža, podaci u IoT mrežama su ili u tranzitu („podaci u pokretu“) ili se čuvaju ili memorišu („podaci u mirovanju“).
- ❑ Primjeri podataka u pokretu uključuju tradicionalne razmjene klijent/server, kao što su pretraživanje weba, prenos datoteka i e-pošta.
- ❑ Podaci sačuvani na hard disku su podaci u mirovanju.
- ❑ Iz perspektive IoT-a, podaci iz pametnih objekata smatraju se podacima u pokretu dok prolaze kroz mrežu na putu do konačnog odredišta.
- ❑ Podaci se često obrađuju na edgu (*edge computing*).
- ❑ Prilikom obrade na edge čvorovima, podaci se mogu se filtrirati/izbrisati ili proslijediti na dalju obradu i moguće memorisanje na fog čvor ili u data centar.
- ❑ Podaci se ne zaustavljaju na edge čvoru.

Uvod

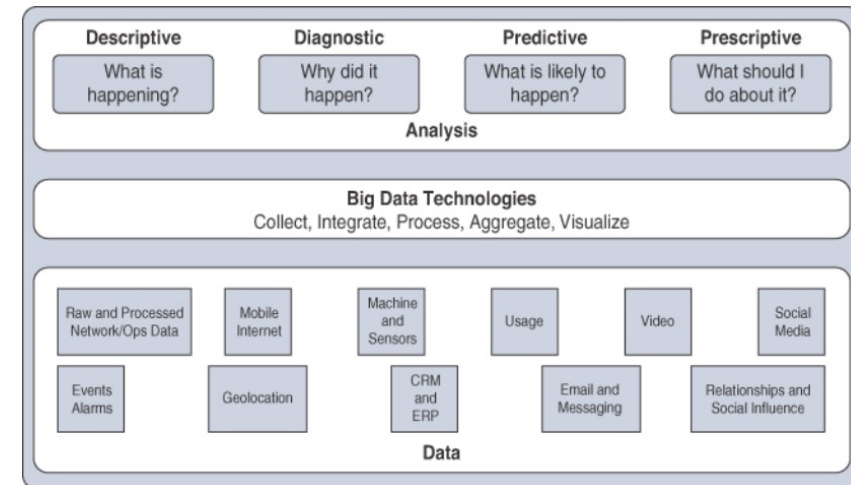
Kretanje podataka

- ❑ Kada podaci stignu u data centar, moguće ih je obraditi u realnom vremenu, baš kao na edge čvoru, dok su još u pokretu.
- ❑ Alati sa ovom vrstom mogućnosti, kao što su Spark, Storm i Flink, relativno su novi u poređenju sa alatima za analizu memorisanih podataka.
- ❑ Podaci u mirovanju u IoT mrežama se obično mogu naći u IoT brokerima ili u data centru.
- ❑ Bezbroj alata, posebno alata za strukturirane podatke u relacionim bazama podataka, dostupno je iz perspektive analize podataka.
- ❑ Najpoznatiji od ovih alata je Hadoop.
- ❑ Hadoop ne pomaže samo u obradi podataka već i u memorisanju podataka.

Uvod

Pregled IoT analize podataka

- Prava važnost IoT podataka iz pametnih objekata spoznaje se samo kada analiza podataka dovede do poslovne inteligencije i načina na koji se mogu primijeniti.
- Analiza podataka je obično raščlanjena prema vrstama rezultata koji se proizvode na:
 - Deskriptivnu
 - Dijagnostičku
 - Prediktivnu
 - Preskriptivnu



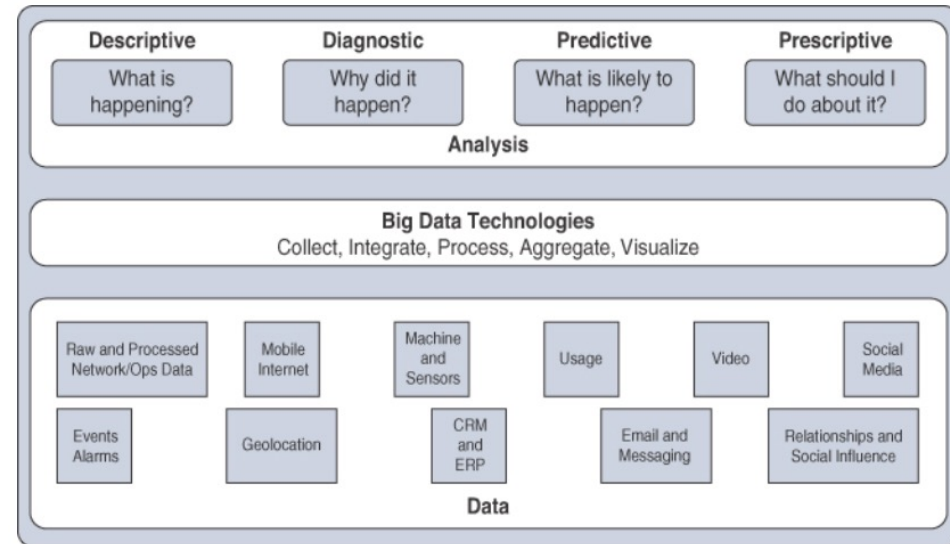
David Hanes, et al, "IoT Fundamentals: Networking Technologies, Protocols, and Use Cases for the Internet of Things", Cisco Press, 2017, SAD

Uvod

Pregled IoT analize podataka

Deskriptivna analiza

- ❑ Deskriptivna analiza podataka govori šta se dešava sada ili šta se desilo u prošlosti.
- ❑ Na primjer, termometar u motoru kamiona prijavljuje temperaturne vrijednosti svake sekunde.
- ❑ Iz perspektive deskriptivne analize, ovi podaci se mogu izvući u svakom trenutku kako bi se stekao uvid u trenutno radno stanje motora kamiona.
- ❑ Ako je vrijednost temperature previsoka, možda postoji problem s hlađenjem ili je motor preopterećen.



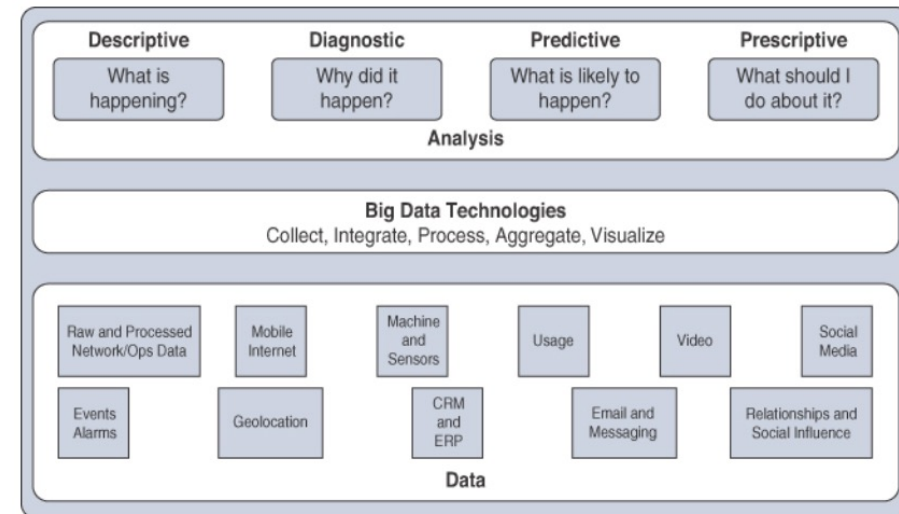
David Hanes, et al, "IoT Fundamentals: Networking Technologies, Protocols, and Use Cases for the Internet of Things", Cisco Press, 2017, SAD

Uvod

Pregled IoT analize podataka

Dijagnostička analiza

- Kada je potrebno naći odgovor na pitanje "zašto", analiza dijagnostičkih podataka daje odgovor.
- Nastavljajući s primjerom senzora temperature u motoru kamiona, mogli bi se postaviti pitanje zašto je motor kamiona otkazao.
- Dijagnostička analiza može pokazati da je temperatura motora bila previsoka i da se motor pregrijao.
- Primjena dijagnostičke analize na podatke generisane od strane širokog spektra pametnih objekata može pružiti jasnu sliku zašto je došlo do problema ili događaja.



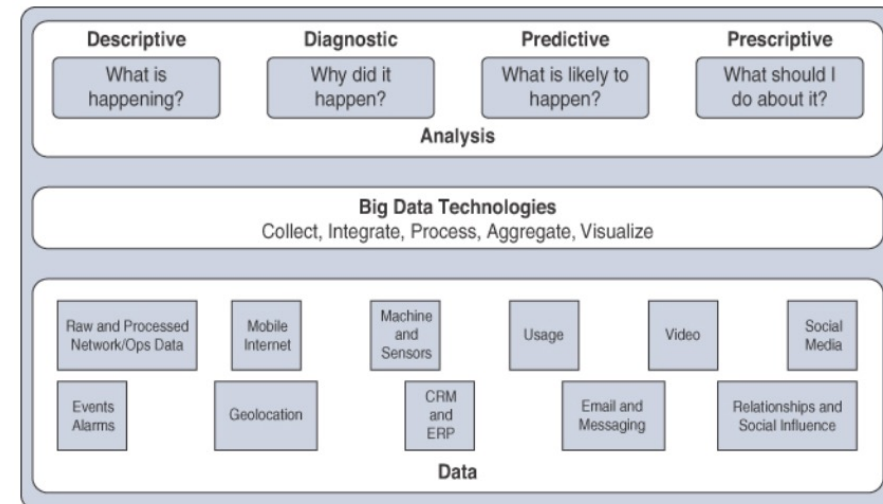
David Hanes, et al, "IoT Fundamentals: Networking Technologies, Protocols, and Use Cases for the Internet of Things", Cisco Press, 2017, SAD

Uvod

Pregled IoT analize podataka

Prediktivna analiza

- ❑ Prediktivna analiza ima za cilj da predvidi probleme čak i prije nego što se pojave.
- ❑ Na primjer, sa istorijskim vrijednostima temperatura za motor kamiona, prediktivna analiza bi mogla dati procjenu preostalog vijeka trajanja određenih komponenti u motoru.
- ❑ Ove komponente bi se tada mogle proaktivno zamijeniti prije nego što dođe do kvara.
- ❑ Ili možda ako vrijednosti temperature motora kamiona počnu polako rasti tokom vremena, to bi moglo ukazivati na potrebu zamjene ulja ili neke druge vrste održavanja hlađenja motora.



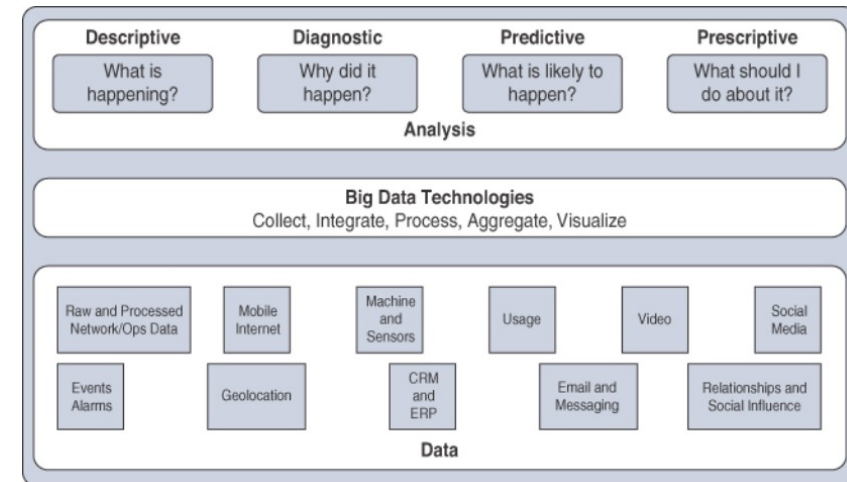
David Hanes, et al, "IoT Fundamentals: Networking Technologies, Protocols, and Use Cases for the Internet of Things", Cisco Press, 2017, SAD

Uvod

Pregled IoT analize podataka

Prediktivna analiza

- ❑ Preskriptivna analiza ide korak dalje od predviđanja i preporučuje rješenja za nadolazeće probleme.
- ❑ Preskriptivna analiza podataka o temperaturi iz motora kamiona mogla bi izračunati različite alternative za ekonomično održavanje kamiona.
- ❑ Ovi proračuni mogu se kretati od troškova potrebnih za češće promjene ulja i održavanja hlađenja do ugradnje nove opreme za hlađenje na motor ili nadogradnje na model kamiona sa snažnijim motorom.
- ❑ Preskriptivna analiza sagledava niz faktora i daje odgovarajuću preporuku.

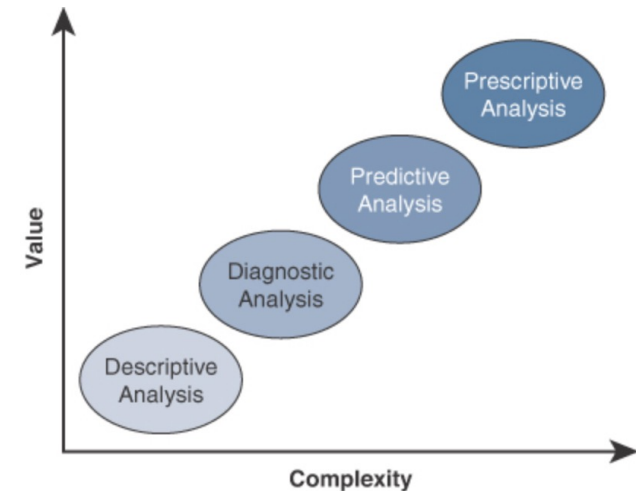


David Hanes, et al, "IoT Fundamentals: Networking Technologies, Protocols, and Use Cases for the Internet of Things", Cisco Press, 2017, SAD

Uvod

Pregled IoT analize podataka

- ❑ I prediktivne i preskriptivne analize zahtijevaju više resursa i povećavaju složenost, ali vrijednost koju pružaju mnogo je veća od vrijednosti iz deskriptivne i dijagnostičke analize.
- ❑ Slika ilustruje četiri tipa analize podataka i kako se oni rangiraju prema povećanju složenosti i vrijednosti.
- ❑ Može se vidjeti da je deskriptivna analiza najmanje složena i da u isto vrijeme nudi najmanju vrijednost.
- ❑ S druge strane, preskriptivna analiza pruža najveću vrijednost, ali je najkompleksnija za implementaciju.
- ❑ Većina analiza podataka u IoT prostoru oslanja se na deskriptivnu i dijagnostičku analizu, ali su za većinu preduzeća i organizacija razumljiv veoma zanimljive prediktivna i preskriptivna analizi.



David Hanes, et al, "IoT Fundamentals: Networking Technologies, Protocols, and Use Cases for the Internet of Things", Cisco Press, 2017, SAD

Uvod

Pregled IoT analize podataka

Izazovi IoT analize podataka

- ❑ Kako je IoT rastao i evoluirao, postalo je jasno da tradicionalna rješenja za analizu podataka nisu uvijek adekvatna.
- ❑ Na primjer, tradicionalna analiza podataka obično koristi standardne relacije baze podataka i odgovarajuće alate, ali svijet IoT-a je mnogo zahtjevniji.
- ❑ Iako se relacije baze podataka još uvijek koriste za određene tipove podataka i aplikacije, one se često imaju problema sa prirodom IoT podataka.
- ❑ IoT podaci postavljaju dva specifična izazova za relacionu bazu podataka:
 - Problemi sa skaliranjem
 - Promjenljivost podataka

Uvod

Pregled IoT analize podataka

Izazovi IoT analize podataka

❑ Problemi sa skaliranjem

- Zbog velikog broja pametnih objekata u većini IoT mreža koji kontinuirano šalju podatke, relacione baze podataka mogu vrlo brzo postati nevjerovatno velike.
- Ovo može rezultirati problemima s performansama koje može biti skupo za rješavanje, često zahtijevajući promjene hardvera i arhitekture.

❑ Promjenljivost podataka:

- Kod relacionih baza podataka, ključno je da šema bude ispravno dizajnirana od početka.
- Kasnija promjena može usporiti ili zaustaviti rad baze podataka.
- Zbog nedostatka fleksibilnosti, revizije šeme moraju biti svedene na minimum.
- IoT podaci su, međutim, nestabilni u smislu da će se model podataka vjerovatno mijenjati i razvijati tokom vremena.
- Često je potrebna dinamička šema tako da se promjene modela podataka mogu vršiti dnevno ili čak svaki sat.

Uvod

Pregled IoT analize podataka

Izazovi IoT analize podataka

- ❑ Za rješavanje izazova kao što su skaliranje i promjenljivost podataka, koristi se drugačiji tip baze podataka, poznat kao NoSQL.
- ❑ Structured Query Language(SQL) se koristi za komunikaciju sa relacionom bazom podataka.
- ❑ Kao što naziv implicira, NoSQL baza podataka je baza podataka koja ne koristi SQL.
- ❑ NoSQL nije postavljen u tradicionalnom tabelarnom obliku relacione baze podataka.
- ❑ NoSQL baze podataka ne primjenjuju striktnu šemu i podržavaju složeni, evoluirajući model podataka.
- ❑ Ove baze podataka su takođe inherentno mnogo skalabilnije.

Uvod

Pregled IoT analize podataka

Izazovi IoT analize podataka

- ❑ Pored izazova vezanih za relacione baze podataka koje nameće IoT, sa svojom velikom količinom podataka o pametnim objektima koji se često mijenjaju, IoT takođe donosi izazove s prirodom *live streaming-a* podataka i upravljanjem podacima na nivou mreže.
- ❑ *Streaming* podataka, koji se generišu dok pametni objekti prenose podatke, predstavlja izazov jer je obično vrlo velikog obima, a vrijedan je samo ako ga je moguće analizirati i kreirati odgovore na njega u realnom vremenu.
- ❑ Analiza *streaming* podataka u realnom vremenu omogućava da se otkriju obrasci ili anomalije koje bi mogle ukazivati na problem ili situaciju na koju je potrebna neka vrsta trenutnog odgovora.
- ❑ Da bi postojala šansa uticaja na ishod ovog problema, naravno mora postojati mogućnosti da se filtriraju i analiziraju podaci na edge čvorovima.
- ❑ Tržište za analizu *streaming* podataka u realnom vremenu brzo raste.
- ❑ Glavni provajderi analize u *cloudu*, kao što su Google, Microsoft i IBM, imaju ponude za *streaming* analizu.

Uvod

Pregled IoT analize podataka

Izazovi IoT analize podataka

- ❑ Još jedan izazov koji IoT donosi u analizi podataka je u području mrežnih podataka, koji se naziva mrežna analiza.
- ❑ Uz veliki broj pametnih objekata u IoT mrežama koji komuniciraju i strimuju podatke, može biti izazovno osigurati da se tim tokovima podataka efikasno upravlja, nadgleda i osigurava.
- ❑ Alati za mrežnu analizu kao što su Flexible NetFlow i IPFIX pružaju mogućnost otkrivanja nepravilnih obrazaca ili drugih problema u tokovima IoT podataka kroz mrežu.

Mašinsko učenje

- ❑ Jedna od ključnih tema u IoT-u je kako dati smisao podacima koji se generišu.
- ❑ Mašinsko učenje (*Machine Learning* - ML) omogućava da se u velikom dijelu ovih podataka, koji su na prvi pogled nerazumljivi, pronađe njihov puni smisao.
- ❑ Mašinsko učenje, duboko učenje (*Deep Learning* - DL), neuronske mreže (*Neural Networks* - NN) i konvolucione mreže (*Convolutional Networks* - CN) su ključne tehnologije za obradu Big Data u IoT.
- ❑ ML ima centralno mjesto u IoT, jer je podatke prikupljene pametnim objektima potrebno analizirati, a na osnovu tih analiza potrebno je preduzeti inteligentne radnje.
- ❑ Izvođenje ove vrste operacija ručno je gotovo nemoguće (ili vrlo, vrlo sporo i neefikasno).
- ❑ Računari su potrebni za brzu obradu informacija i trenutnu reakciju kada se dostignu određeni pragovi.

Mašinsko učenje

- Mašinsko učenje je dio većeg skupa tehnologija koje se obično grupišu pod pojmom vještačka inteligencija (*Artificial Intelligence* - AI).
- AI uključuje tehnologije koje omogućavaju računaru da oponaša ljudsku inteligenciju koristeći bilo koju tehniku, od vrlo napredne logike do osnovnih petlji odlučivanja „if-then-else“.
- Jednostavan primjer je aplikacija koja može pomoći pronalaženje parkiranog automobila.
 - GPS očitavanje pozicije u redovnim intervalima izračunava brzinu kretanja.
 - Osnovni sistem praga određuje da li korisnik vozi (na primjer, "ako je brzina > 30km/h, onda početi računati brzinu").
 - Nakon parkiranja i prekida vezu sa Bluetooth sistemom automobila, aplikacija jednostavno snima lokaciju kada dođe do prekida veze.
 - Ovdje je automobil parkiran. Osim korišćenja AI (računar zna da je korisnik parkiran i gdje se to dogodilo), skup pravila je vrlo jednostavan.

Mašinsko učenje

- ❑ U složenijim slučajevima, statička pravila se ne mogu jednostavno ugraditi u program jer zahtijevaju parametre koji se mogu promijeniti ili koji se ne razumiju.
- ❑ Tipičan primjer je program za diktiranje koji radi na računaru.
- ❑ Program je konfigurisan da prepozna audio obrazac svake riječi u rječniku, ali ne poznaje specifičnosti glasa - naglasak, ton, brzinu itd.
- ❑ Mora se snimiti skup unaprijed određenih rečenica kako bi se pomoglo alatu da uskladi dobro poznate riječi sa zvukovima koji se čuju kada se izgovore.
- ❑ Ovaj proces se naziva mašinsko učenje.
- ❑ ML se bavi bilo kojim procesom u kojem računar treba da primi skup podataka koji se obrađuju kako bi se zadatak izvršio efikasnije.
- ❑ ML je ogromno polje, ali se jednostavno može podijeliti u dvije glavne kategorije:
 - učenje pod nadzorom (*Supervised Learning*)
 - učenje bez nadzora (*Unsupervised Learning*)

Mašinsko učenje

Supervised Learning

- Računar se obučava ulaznim podacima za koje postoje poznati tačni odgovori.
- Da bi se razvio sistem prepoznavanja kada se čovjek nalazi u nekom prostoru potrebno je sledeće:
 - Senzor opremljen osnovnom kamerom može snimiti oblike i poslati ih u računarski sistem koji je odgovoran za određivanje da li je oblik čovjek ili nešto drugo.
 - Sa ovom tehnikama učenja stotine ili hiljade slika se unose u računar i „svaka slika čovjeka ili nečeg drugog je označena, što čini set za obuku.
 - Algoritam se koristi za određivanje uobičajenih parametara i razlika između slika.
 - Poređenje se obično radi na skali cijele slike, ili piksel po piksel.
 - Slike se mijenjaju kako bi imale iste karakteristike (rezolucija, boje, položaj centralne figure itd.), a svaka tačka se analizira.
 - Ljudske slike imaju određene vrste oblika i piksela na određenim lokacijama (koje odgovaraju položaju lica, nogu, usta itd.).
 - Svaka nova slika se upoređuje sa skupom poznatih "dobrih slika", a odstupanje se izračunava kako bi se utvrdilo koliko se nova slika razlikuje od prosječne ljudske slike i, prema tome, vjerovatnoća da je ono što je prikazano ljudska figura.
 - Ovaj proces se naziva klasifikacija.

Mašinsko učenje

Supervised Learning

- Da bi se razvio sistem prepoznavanja kada se čovjek nalazi u nekom prostoru potrebno je sledeće (nastavak):
 - Nakon treniranja, računar bi trebao biti u stanju prepoznati ljudske oblike.
 - Prije stvarnih primjena na terenu, računar se obično testira sa neobilježenim slikama - što se zove validacija na testnom skupu, zavisno o korišćenom ML sistemu - kako bi se potvrdilo da li je nivo prepoznavanja na prihvatljivim pragovima.
 - Ako mašina ne dostigne očekivani nivo uspjeha, potrebna je dodatna obuka.
 - U drugim slučajevima, proces učenja nije u svrstavanju u dvije ili više kategorija, već u pronalaženju ispravne vrijednosti.
 - Na primjer, brzina protoka ulja u cijevi je funkcija veličine cijevi, viskoznosti ulja, pritiska i nekoliko drugih faktora.
 - Kada se trenira mašina sa izmjerenim vrijednostima, mašina može predvidjeti brzinu protoka za novi, neizmjereni, viskozitet.
 - Prethodni proces se naziva regresija; regresija predviđa numeričke vrijednosti, dok klasifikacija predviđa kategorije.

Mašinsko učenje

Unsupervised Learning

- ❑ U nekim slučajevima, *supervised learning* nije najbolja metoda da računar pomogne pri donošenju ljudske odluke.
- ❑ Na primjer, na motorima sa stotinama dijelova može biti vrlo teško otkriti potencijalne kvarove, a gotovo je nemoguće obučiti računar da prepozna probleme koji možda nijesu vidljivi.
- ❑ Međutim, može se testirati svaki motor i snimiti više parametara, kao što su zvuk, pritisak, temperatura ključnih dijelova, itd.
- ❑ Kada se podaci zabilježe, mogu se prikazati grafikoni ovih elemenata u odnosu jedan prema drugom (na primjer, temperatura kao funkcija pritiska, zvuk u odnosu na brzinu rotacije tokom vremena).
- ❑ Zatim se mogu unijeti podaci u računar i koristiti matematičke funkcije za pronalaženje grupa.
- ❑ Na primjer, mogu se grupisati motori prema zvuku koji ispuštaju na datoj temperaturi.

Mašinsko učenje


Unsupervised Learning

- Standardna funkcija za upravljanje ovim grupisaanjem, *K-means clustering*, pronalazi srednje vrijednosti za grupu motora (na primjer, srednja vrijednost za temperaturu, srednja frekvencija za zvuk).
- Grupisanje motora na ovaj način može brzo otkriti nekoliko tipova motora koji svi pripadaju istoj kategoriji (na primjer, mali motor, srednji motor,...).
- Svi motori istog tipa proizvode zvukove i temperature u istom rasponu kao i ostali članovi iste grupe.
- Povremeno će u grupi biti motor koji pokazuje neobične karakteristike (malo izvan očekivanog temperaturnog ili zvučnog opsega).
- Ovo je motor koji se šalje na manuelnu procjenu.
- Ovakav proces se naziva *unsupervised learning*.
- Ova vrsta učenja nema unaprijed poznate odgovore „dobar“ ili „loš“.

Mašinsko učenje

Unsupervised Learning

- To je varijacija od grupnog ponašanja koja omogućava računaru da nauči da je nešto drugačije.
- Primjer motora je, naravno, vrlo jednostavan kod koga su u većini slučajeva, parametri višedimenzionalni.
- Izračunavaju se stotine ili hiljade parametara, a mala akumulirana odstupanja u više dimenzija koriste se za identifikaciju izuzetka.
- Na slici su prikazane tri parametra (komponente 1, 2 i 3), a pronađene su četiri različite grupe (klastera).
- Mogu se vidjeti neke tačke koje su udaljene od odgovarajućih grupa.
- Pojedinačne uređaje koji pokazuju takve karakteristike „van klastera“ treba pažljivije ispitati.



David Hanes, et al, "IoT Fundamentals: Networking Technologies, Protocols, and Use Cases for the Internet of Things", Cisco Press, 2017, SAD

Mašinsko učenje

Neuronske mreže

- ❑ Višedimenzionalna obrada zahtijeva moćne računarske procesore.
- ❑ Teško je odrediti koje parametre treba unijeti i koje kombinovane varijacije treba da izazovu posebnu pažnju.
- ❑ *Supervised learning* je efikasan samo sa velikim setom treniranja jer obično dovode do veće preciznosti u predviđanju, što je nekad bilo preskup i komplikovano.
- ❑ Jeftini računarski procesori zajedno sa pristupom veoma velikim skupovima podataka (koji se dijele preko Interneta) otvorile su nove mogućnosti za ML-a.
- ❑ Postignut je ogroman napredak u efikasnosti korišćenih algoritama.
- ❑ U slučaju prepoznavanja ljudskog oblika lako je razlikovati čovjeka od automobila.
- ❑ Računar može prepoznati da ljudi imaju različite oblike (kao što su noge ili ruke), a da vozila nemaju.
- ❑ Razlikovanje čovjeka od drugog sisara je mnogo teže što važi i za razlikovanje kamiona i kombija.

Mašinsko učenje

Neuronske mreže

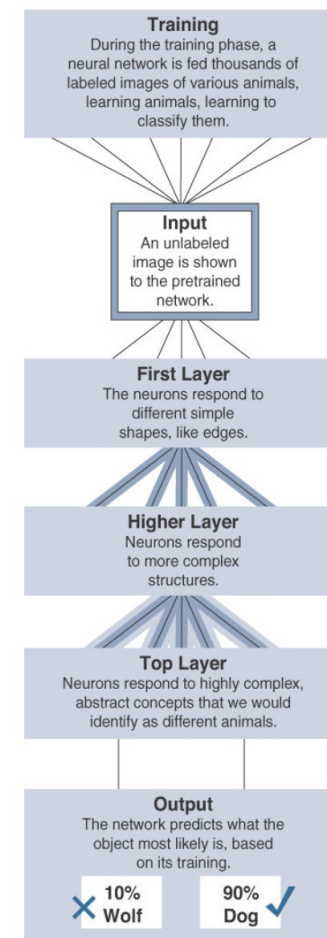
- ❑ U tim slučajevima se koriste neuronske mreže.
- ❑ Neuronske mreže su ML metode koje oponašaju način na koji ljudski mozak radi.
- ❑ Kada se gleda ljudsku figuru, aktivira se više zona mozga za prepoznavanje boje, pokreta, izraza lica,...
- ❑ Mozak kombinuje ove elemente kako bi zaključio da li je oblik ljudski.
- ❑ Neuronske mreže oponašaju istu logiku.
- ❑ Informacije prolaze kroz različite algoritme (zване jedinice), od kojih je svaki zadužen za obradu nekog aspekta informacije.
- ❑ Rezultirajuća vrijednost proračuna jedne jedinice može se koristiti direktno ili se unositi u drugu jedinicu radi dalje obrade.
- ❑ U ovom slučaju se kaže da neuronska mreža ima nekoliko slojeva.

Mašinsko učenje

Neuronske mreže

- Neuronska mreža koja obrađuje prepoznavanje ljudske slike može imati dvije jedinice u prvom sloju koje određuju da li slika ima ravne linije i oštre uglove - jer vozila obično imaju ravne linije i oštre uglove, a ljudske figure nemaju.
- Ako slika uspješno prođe prvi sloj (jer nema ili je samo mali procenat oštih uglova i ravnih linija), drugi sloj može tražiti različite karakteristike (prisustvo lica, ruku,...)
- Treći sloj bi upoređuje sliku sa slikama raznih životinja i zaključuje da li je oblik čovjek (ili ne).
- Velika efikasnost neuronskih mreža je u tome što svaka jedinica obrađuje jednostavan test, pa je računanje prilično brzo.

How Neural Networks Recognize a Dog in a Photo



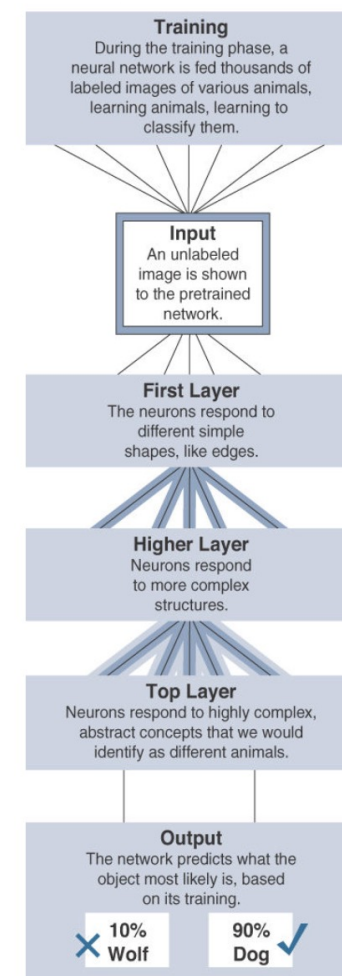
David Hanes, et al, "IoT Fundamentals: Networking Technologies, Protocols, and Use Cases for the Internet of Things", Cisco Press, 2017, SAD

Mašinsko učenje

Neuronske mreže

- Suprotno prethodnom stare *supervised learning* tehnike bi upoređivale ljudsku figuru sa potencijalno stotinama hiljada slika tokom faze obuke, piksel po piksel, što bi ih činilo teškim za implementaciju (sa potrebnom puno obuke) i sporim za rad.
- Neuronske mreže su bile predmet mnogih istraživanja.
- Višestruka istraživanja i naponi na optimizaciji ispitali su broj jedinica i slojeva, tip podataka koji se obrađuju na svakom sloju i vrstu i kombinaciju algoritama koji se koriste za obradu podataka kako bi obrada bila efikasnija za specifične aplikacije.
- Obrada slika može se optimizovati određenim tipovima algoritama koji možda nisu optimalni za klasifikaciju kretanja.
- U ovom slučaju se može naći još jedan algoritam koji bi revolucionirao način na koji se ti pokreti obrađuju i analiziraju.
- Mogućnosti su brojne koliko i aplikacije u kojima se mogu koristiti.

How Neural Networks Recognize a Dog in a Photo



David Hanes, et al, "IoT Fundamentals: Networking Technologies, Protocols, and Use Cases for the Internet of Things", Cisco Press, 2017, SAD

Mašinsko učenje

Mašinsko učenje i sticanje inteligencije iz velikih podataka

- Kada su principi mašinskog učenja jasni, primjena IoT-a postaje očigledna.
- Poteškoća je u određivanju pravog algoritma i pravog modela učenja za svaki slučaj upotrebe, ali se ML tehnike mogu razmatrati u dvije široke podgrupe:
 - Lokalno učenje: U ovoj grupi podaci se prikupljaju i obrađuju lokalno, bilo u samom senzoru (edge čvor) ili u gateway-u (fog čvor).
 - Učenje na daljinu: U ovoj grupi podaci se prikupljaju i šalju u centralnu računarsku jedinicu (obično u data centar na određenoj lokaciji ili u cloudu), gdje se obrađuju.

Mašinsko učenje

Mašinsko učenje i dobijanje inteligencije iz velikih podataka

- Bez obzira na lokaciju na kojoj se (i, prema tome, na kojoj se mjeri) podaci obrađuju, uobičajene aplikacije ML-a za IoT se vrte oko četiri glavna domena:
 - Nadgledanje: Pametni objekti nadgledaju okruženje u kojem rade, podaci se obrađuju radi boljeg razumijevanja uslova okruženja pri čemu se ML koristi za ranu detekciju događaja ili za bolju procjenu okoline.
 - Kontrola ponašanja: Nadgledanje obično radi u sprezi s kontrolom ponašanja, pa kada dati skup parametara dostigne ciljani definisani prag funkcije praćenja generišu alarm koji se može prenijeti na čovjeka, ali efikasniji i napredniji sistem bi pokrenuo korektivnu akciju, kao što je povećanje protoka svježeg vazduha u tunelu rudnika, okretanje robotske ruke ili smanjenje pritiska ulja u cijevi.
 - Optimizacija operacija: Kontrola ponašanja obično ima za cilj preduzimanje korektivnih radnji na osnovu pragova, ali analiza podataka korišćenjem neuralnih mreža može dovesti i do promjena koje poboljšavaju ukupan proces poboljšanjem njegove efikasnosti.
 - Samoizlječenje, samooptimiziranje: Aspekt *deep learninga* je korišćenje zatvorene petlje, tako da praćenje zasnovano na ML-u pokreće promjene u ponašanju nadgledanog objekta i optimizacije operacija, pri čemu se sam objekat može programirati da dinamički prati i kombinuje nove parametre (nasumično ili polu-slučajno) i automatski izvodi i implementira nove optimizacije kada rezultati pokažu moguću dobit tako da sistem sam uči i samooptimizuje. Detekcijom novih odstupanja *K-means* devijacije koja rezultiraju otkrivanjem novih potencijalnih problema, omogućavajući sistemu da se samoizliječi.

Mašinsko učenje

Mašinsko učenje i sticanje inteligencije iz velikih podataka

- ❑ Za sve ove operacije, specifičan aspekt ML-a za IoT je veličina.
- ❑ Senzor postavljen na stub rasvjete na ulici može pružiti informacije o lokalnom nivou zagađenja.
- ❑ Na nivou cijelog grada, odgovarajuće institucije mogu pratiti oblake zagađenja, globalne i lokalne efekte magle ili vlage, pritisak i teren.
- ❑ Sve ove informacije mogu se kombinovati sa podacima o saobraćaju kako bi se globalno regulisali semafori, smanjile emisije iz industrijskih izvora zagađenja ili povećala gustina vozila za masovni prevoz duž pravaca koji su više pogođeni.
- ❑ U međuvremenu, na lokalnom nivou, LED na rasvjetnom stubu može povećati ili smanjiti svoju svjetlost i promijeniti boju kako bi se prilagodila lokalnim uslovima što može biti regulisano obradom lokalnih uslova (lokalno učenje) ili naslijeđenim učenjem.
- ❑ Sposobnost kombinovanja *fog computing*-a na specifičnim i specijalizovanim sistemima sa *cloud computingom* na podacima koji dolaze iz više izvora i izvođenjem globalnih ili lokalnih korektivnih radnji ono je što ML čini tako moćnim za IoT.
- ❑ Sa otvorenim sistemima i ekspanzijom pametnih objekata, mogućnosti korelacija i unakrsnih optimizacija su veoma široke.

Mašinsko učenje

Prediktivna analiza

- ❑ Mašinsko učenje i obrada velikih podataka za IoT se vrlo dobro uklapaju u digitalizaciju društva.
- ❑ U naprednim fazama ovog modela mreža se samodijagnostikuje i samooptimizuje.
- ❑ U IoT okruženju, kada se podaci iz više sistema kombinuju i analiziraju neki sistem zajedno, mogu se napraviti predviđanja o stanju sistema.
- ❑ Svi ovi podaci mogu se vratiti u centar za obradu podataka u *cloud*-u koji može ponovo kreirati virtuelnog blizanca svakog sistema.
- ❑ Modeliranje stanja svakog sistema i kombinovanje ovog znanja sa predviđenim kretanjem i stanjima (i otkrivenim kvarovima) svih drugih sistema istog tipa omogućava analitičkoj platformi da napravi vrlo tačna predviđanja o tome koji će problem vjerovatno uticati na svako vozilo.
- ❑ Takva prediktivna analiza omogućava preventivno održavanje i povećava sigurnost i efikasnost rada.

Big data tehnologije analize

- ❑ Analiza velikih podataka može se sastojati od mnogo različitih softverskih djelova koji zajedno prikupljaju, memorišu, obrađuju i analiziraju sve različite vrste podataka.
- ❑ Pomaže u boljem razumijevanju okruženja definisanjem šta su veliki podaci, a šta nisu.
- ❑ Generalno, industrija gleda na "tri protiv" da bi kategorisala velike podatke:
 - Brzina: Brzina se odnosi na to koliko brzo se podaci prikupljaju i analiziraju. *Hadoop Distributed File System* je dizajniran da vrlo brzo unosi i obrađuje podatke. Pametni objekti mogu generisati podatke o mašinama i senzorima vrlo velikom brzinom i zahtijevaju bazu podataka koja je sposobna za jednako brze funkcije unosa.
 - Raznolikost: Raznolikost se odnosi na različite vrste podataka. Podaci mogu biti kategorisani kao strukturirani, polustrukturirani ili nestrukturirani. Različite tehnologije baza podataka mogu prihvatiti samo jedan od ovih tipova. Hadoop može prikupiti i memorisati sve tri vrste. Ovo može biti korisno kada se kombinuju podaci sa IoT uređaja koji su po prirodi veoma strukturirani sa podacima iz drugih izvora, kao što su društveni mediji ili multimedija, koji su nestrukturirani.
 - Obim: Obim se odnosi na veličinu podataka. Obično se mjeri od gigabajta na najnižem nivou do petabajta ili čak eksabajta podataka. Implementacije velikih podataka su veće od onoga što je dostupno na lokalno priključenim diskovima za memorisanju na jednom čvoru. Uobičajeno je vidjeti klastere servera koji se sastoje od desetina, stotina ili čak hiljada čvorova za neke velike implementacije.

Big data tehnologije analize

- ❑ Karakteristike velikih podataka mogu se definisati izvorima i vrstama podataka.
- ❑ Prvi su mašinski podaci, koje generišu IoT uređaji i obično su nestrukturirani podaci.
- ❑ Drugo su transakcioni podaci, koji potiču iz izvora koji proizvode podatke iz transakcija na ovim sistemima, i imaju veliki obim i strukturiranost.
- ❑ Treći su društveni izvori podataka, koji su obično velikog obima i strukturirani.
- ❑ Četvrti su podaci preduzeća, koji su podaci manjeg obima i vrlo strukturirani.
- ❑ Veliki podaci se sastoje od podataka iz svih ovih izvora.

Big data tehnologije analize

- ❑ Dodatno prilikom pregleda izvora podataka treba uzeti u obzir količinu podataka unesenih iz svakog izvora, što određuje dizajn sloja čuvanja podataka.
- ❑ Mora se razmotriti i mehanizam za dobijanje podataka iz sistema za unos podataka
 - push
 - pull.
- ❑ Tip izvora podataka (baza podataka, datoteka, web usluga, tok,...) treba uzeti u obzir jer i on određuje strukturu podataka.
- ❑ Unos podataka je sloj koji povezuje izvore podataka sa memorijskim resursima, prethodno obrađujući, potvrđujući, izdvajajući i privremeno memorišući podatke za dalju obradu.
- ❑ Postoji nekoliko obrazaca koje treba uzeti u obzir za unos podataka.
 - Prvo je dobijanje podataka iz više izvora, koja povezuje više izvora podataka sa sistemima za unos podataka. U ovom obrascu, čvorovi za unos podataka primaju tokove podataka iz više izvora i obavljaju obradu prije prosljeđivanja podataka srednjim čvorovima i konačnim čvorovima memorije. Ovaj obrazac se obično implementira u paketnim sistemima i (rjeđe, zbog kašnjenja u dostupnosti podataka) u sistemima u realnom vremenu.
- ❑ Prikupljanje i analiza podataka nisu novi koncepti u industrijama koji su pomogli u definisanju IoT-a. Industrijske vertikale dugo su zavisile o mogućnosti dobijanja, prikupljanja i snimanja podataka iz različitih procesa kako bi se zabilježili trendovi i pratili učinak i kvalitet.

Big data tehnologije analize

- ❑ Mnogi sistemi industrijske automatizacije i kontrole unose podatke u dvije različite vrste baza podataka, relacione baze podataka i historians.
- ❑ Relacione baze podataka, kao što su Oracle i Microsoft SQL, dobre su za transakcione ili procesne podatke. Njihova prednost je u mogućnosti da analiziraju složene odnose podataka na podacima koji stižu tokom određenog vremenskog perioda.
- ❑ Historians su optimizovani za vremenske serije podataka iz sistema i procesa. Izgrađeni su sa brzinom memorisanja i preuzimanja podataka, beležeći svaku tačku podataka u nizu sa relevantnim informacijama o sistemu koji se evidentira. Ovi podaci se mogu sastojati od očitavanja senzora, količine materijala, očitavanja temperature ili podataka o protoku.
- ❑ Relacione baze podataka i historians su zrele tehnologije koje se koriste dugi niz godina, ali nove tehnologije i tehnike na tržištu upravljanja podacima otvorile su nove mogućnosti za senzorske i mašinske podatke.
- ❑ Nove tehnologije baza podataka se uglavnom uklapaju u nekoliko kategorija od kojih svaka ima prednosti i potencijalne nedostatke kada se koristi u kontekstu IoT.
- ❑ Tri najpopularnije od ovih kategorija su sistemi masovne paralelne obrade, NoSQL i Hadoop.

Big data tehnologije analize


Massively Parallel Processing (MPP) baze podataka

- ❑ Preduzeća su decenijama koristila relacione baze podataka za memorisanje strukturiranih tipova podataka u formi redova i kolona.
- ❑ Relacione baze podataka se često grupišu u široku kategoriju skladišta podataka koja se naziva warehouse.
- ❑ Iako su središnji dio većine arhitektura podataka, često se koriste za dugotrajnije arhiviranje i upite podataka koji često mogu trajati minutama ili satima.
- ❑ Primjer za to bi bio traženje svih artikala proizvedenih u prošloj godini koji su imali određenu specifikaciju.
- ❑ U zavisnosti od broja stavki u bazi podataka i složenosti pitanja koje se postavlja, odgovor bi mogao biti spor.
- ❑ MPP baze podataka izgrađene su na konceptu relacionih data warehousea, ali su dizajnirane da budu mnogo brže, da budu efikasne i da podrže smanjeno vrijeme upita.
- ❑ MPP baze podataka koriste prednosti višestrukih čvorova (računara) dizajniranih u scale-out arhitekturi tako da se i podaci i obrada distribuiraju u više sistema.

Big data tehnologije analize

Massively Parallel Processing (MPP) baze podataka

- ❑ MPP-ovi se nazivaju analitičkim bazama podataka jer su dizajnirani da omoguće brzu obradu upita i često imaju ugrađene analitičke funkcije.
- ❑ Ovi tipovi baza podataka paralelno obrađuju ogromne skupove podataka u velikom broju procesora i čvorova.
- ❑ MPP arhitektura obično sadrži jedan glavni čvor koji je odgovoran za koordinaciju svih pohranjivanja i obrade podataka u klasteru.
- ❑ Radi na način „ništa ne dijeli“, pri čemu svaki čvor sadrži lokalnu obradu, memoriju i starage i radi nezavisno.
- ❑ Skladištenje podataka je optimizovano preko čvorova u strukturiranom formatu sličnom SQL-u koji omogućava analitičarima podataka da rade s podacima koristeći uobičajene SQL alate i aplikacije.




David Hanes, et al, "IoT Fundamentals: Networking Technologies, Protocols, and Use Cases for the Internet of Things", Cisco Press, 2017, SAD

Big data tehnologije analize

Massively Parallel Processing (MPP) baze podataka

- ❑ Raniji primjer složenog SQL upita može se distribuirati i optimizovati, što rezultira znatno bržim odgovorom.
- ❑ Budući da podaci pohranjeni na MPP-ovima i dalje moraju biti u skladu sa ovom relacionom strukturom, to možda nije najpovoljniji tip baze podataka koji se koristi u implementaciji IoT-a.
- ❑ Izvori i tipovi podataka mogu se razlikovati, što zahtijeva bazu podataka koja je fleksibilnija nego što to dozvoljavaju relacione baze podataka.



David Hanes, et al, "IoT Fundamentals: Networking Technologies, Protocols, and Use Cases for the Internet of Things", Cisco Press, 2017, SAD

Big data tehnologije analize

NoSQL baze podataka

- ❑ NoSQL („ne samo SQL“) je klasa baza podataka koje podržavaju polustrukturirane i nestrukturirane podatke, pored strukturiranih podataka kojima rukuju warehouse i MPP-ovi.
- ❑ NoSQL nije posebna tehnologija baze podataka, to je krovni pojam koji obuhvata nekoliko različitih tipova baza podataka, uključujući sljedeće:
 - Skladišta dokumenata: Ova vrsta baze podataka pohranjuje polustrukturirane podatke, kao što su XML ili JSON. Imaju mehanizme upita i funkcije indeksiranja koje omogućavaju mnogo optimiziranih upita.
 - Skladišta ključ/vrijednost: Ovaj tip baze podataka pohranjuje asocijativne nizove gdje je ključ uparen sa pridruženom vrijednošću. Ove baze podataka je lako napraviti i skalirati.
 - Spremišta širokih kolona: Ova vrsta baze podataka pohranjuje slično spremištu ključ/vrijednost, ali formatiranje vrijednosti može varirati od reda do reda, čak i u istoj tabeli.
 - Skladišta grafova: Ova vrsta baze podataka je organizovana na osnovu odnosa između elemenata. Obično se koriste za društvene mreže ili NLP, gdje su veze između podataka vrlo relevantne.

Big data tehnologije analize

NoSQL baze podataka

- ❑ NoSQL je razvijen da podrži brze, hitne zahtjeve za podacima modernih web aplikacija koje obično ne zahtijevaju mnogo ponavljanja korišćenja.
- ❑ Prvobitna namjera je bila da se brzo unesu brzo promjenljivi serverski logovi i podaci o klikovima koje generišu aplikacije na web-skali koje se ne uklapaju u redove i kolone koje zahtijevaju relacione baze podataka.
- ❑ Slično drugim skladištima podataka, poput MPP-a i Hadoop-a, NoSQL je izgrađen tako da se horizontalno skalira, omogućavajući bazi podataka da obuhvata više hostova, a može se čak i geografski distribuirati.
- ❑ Proširenje NoSQL baza podataka na druge čvorove slično je proširenju u drugim distribuiranim sistemima podataka, gdje dodatnim hostovima upravlja glavni čvor ili proces.
- ❑ Ovo proširenje može biti automatizovano nekim NoSQL implementacijama ili se može obezbijediti ručno. Ovaj nivo fleksibilnosti čini NoSQL dobrim kandidatom za čuvanje podataka mašina i senzora povezanih sa pametnim objektima.

Big data tehnologije analize

NoSQL baze podataka

- ❑ Od tipova baza podataka koji se uklapaju u NoSQL kategoriju, skladišta ključ/vrijednost i skladišta dokumenata obično najbolje odgovaraju onome što se smatra „IoT podacima“.
- ❑ Skladištenje ključ-vrijednosti je tehnologija koja pruža osnovu za mnoge današnje relacione baze podataka, kao što su MS SQL, Oracle i DB2.3
- ❑ Za razliku od tradicionalnih relacionih baza podataka, skladišta ključ-vrijednosti na NoSQL-u nisu ograničena na jedan monolitni sistem.
- ❑ NoSQL skladišta ključ/vrijednost su sposobna za rukovanje indeksiranjem i postojanošću istovremeno velikom brzinom, što ih čini odličnim izborom za skupove podataka vremenske serije, koji bilježe vrijednost u datom vremenskom intervalu, kao što je očitavanje temperature ili pritiska sa senzora.

Big data tehnologije analize

NoSQL baze podataka

- ❑ Dopuštajući da se šema baze podataka brzo mijenja, NoSQL baze podataka dokumentata imaju tendenciju da budu fleksibilnije od baza podataka ključ/vrijednost.
- ❑ Polustrukturirani ili nestrukturirani podaci koji se ne uklapaju uredno u redove i kolone mogu dijeliti istu bazu podataka s organizovanim podacima vremenskih serija.
- ❑ Nestrukturirani podaci mogu imati mnogo oblika, poput fotografija gotove robe na proizvodnoj liniji koja se koristi za osiguranje kvaliteta i izvještaj o održavanju dijela opreme.
- ❑ Mnoge NoSQL baze podataka pružaju dodatne mogućnosti, kao što je mogućnost upita i analize podataka unutar same baze podataka, eliminišući potrebu za njihovim premještanjem i obradom negdje drugdje.
- ❑ Pružaju različite načine za ispitivanje baze podataka putem API-ja, što olakšava njihovu integraciju s drugim aplikacijama za upravljanje podacima.

Big data tehnologije analize

Hadoop

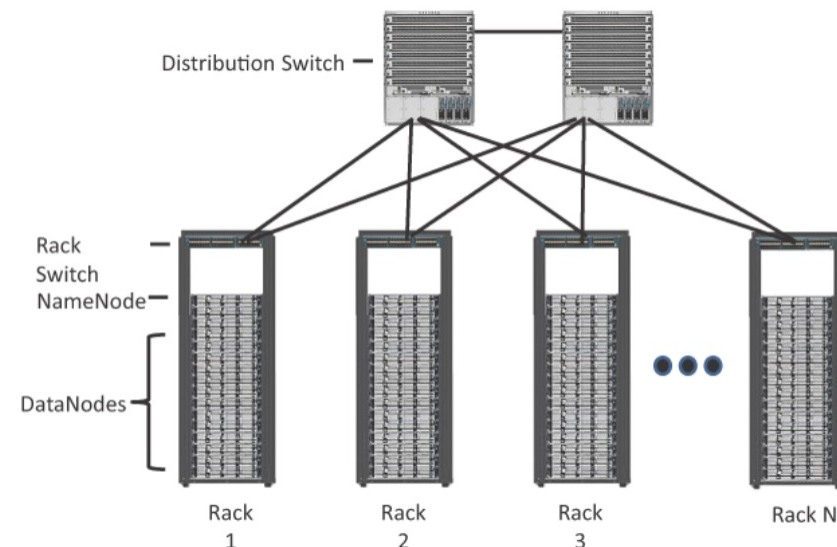
- ❑ Najnoviji akter na tržištu upravljanja podacima, ali i najpopularniji izbor kao repozitorijum podataka i mehanizam za obradu podataka.
- ❑ Hadoop je prvobitno razvijen kao rezultat projekat Google i Yahoo!, a početna namjena Hadoop-a je bila da indeksira milione web stranica i brzo vrati rezultate pretraživanja za pretraživače otvorenog koda.
- ❑ U početku je projekat imao dva ključna elementa:
 - Hadoop Distributed File System (HDFS): Sistem za skladištenje podataka na više čvorova
 - MapReduce: Distribuirana mašina za obradu koja dijeli veliki zadatak na manje koji se mogu izvoditi paralelno

Big data tehnologije analize

Hadoop

□ Slično MPP i NoSQL sistemima, Hadoop se oslanja na scale-out arhitekturu koja koristi lokalnu obradu, memoriju i storage za distribuciju zadataka i obezbjeđivanje skalabilnog sistema skladištenja podataka.

- MapReduce i HDFS koriste prednosti ove distribuirane arhitekture za skladištenje i obradu ogromnih količina podataka i na taj način mogu iskoristiti resurse iz svih čvorova u klasteru. Za HDFS, ovom mogućnošću rukuju specijalizovani čvorovi u klasteru, uključujući
- NameNodes
 - DataNodes




David Hanes, et al, "IoT Fundamentals: Networking Technologies, Protocols, and Use Cases for the Internet of Things", Cisco Press, 2017, SAD

Big data tehnologije analize

Hadoop

- ❑ NameNodes su važni u dodavanju, premještanju, brisanju i čitanju podataka na HDFS.
- ❑ Koordiniraju gdje se podaci pohranjuju i održavaju mapu gdje se svaki blok podataka pohranjuje i gdje se replicira.
- ❑ Sva interakcija sa HDFS-om se koordinira preko primarnog (aktivnog) NameNode-a, sa sekundarnim (rezervnim) NameNode-om koji je obaviješten o promjenama u slučaju kvara primarnog.
- ❑ NameNode prima zahtjeve za pisanje od klijenata i distribuira te datoteke po dostupnim čvorovima u konfigurabilnim veličinama blokova (obično od 64 MB ili 128 MB).
- ❑ NameNode je odgovoran za upućivanje DataNodes-a gdje treba da se dogodi replikacija.




David Hanes, et al, "IoT Fundamentals: Networking Technologies, Protocols, and Use Cases for the Internet of Things", Cisco Press, 2017, SAD

Big data tehnologije analize

Hadoop

- ❑ DataNodes su serveri na kojima se podaci pohranjuju u smjeru NameNode.
- ❑ Uobičajeno je postojanje više DataNodes u Hadoop klasteru za pohranjivanje podataka.
- ❑ Blokovi podataka su raspoređeni na nekoliko čvorova i često se repliciraju tri, četiri ili više puta na čvorove radi redundanse.
- ❑ Jednom kada su podaci upisani u jedan od DataNode-a, DataNode bira dva (ili više) dodatna čvora, na osnovu politika replikacije, kako bi osigurao redundantnost podataka u cijelom klasteru.
- ❑ Tehnike redundanse diska kao što je Redundant Array of Independent Disks (RAID) se ne koriste za HDFS jer čvorovi imena i čvorovi podataka s ovom tehnikom replikacije koordiniraju redundantnost na nivou bloka.




David Hanes, et al, "IoT Fundamentals: Networking Technologies, Protocols, and Use Cases for the Internet of Things", Cisco Press, 2017, SAD

Big data tehnologije analize

Hadoop

- ❑ MapReduce koristi sličan model za batch obradu podataka pohranjenih na čvorovima klastera.
- ❑ Batch obrada je proces pokretanja planiranog ili ad hoc upita za istorijske podatke pohranjene u HDFS.
- ❑ Upit je raščlanjen na manje zadatke i distribuiran na sve čvorove koji pokreću MapReduce u klasteru.
- ❑ Iako je ovo korisno za razumijevanje obrazaca i trendova u istorijskim senzorskim ili mašinskim podacima, ima jedan značajan nedostatak: vrijeme.
- ❑ Zavisno od toga koliko podataka se traži i kakva je složenosti upita, vraćanje rezultata bi moglo potrajati nekoliko sekundi ili minuta.
- ❑ Ako je pokrenut proces u realnom vremenu gdje je potreban trenutni rezultat, MapReduce nije pravi mehanizam za obradu ovih podataka.



David Hanes, et al, "IoT Fundamentals: Networking Technologies, Protocols, and Use Cases for the Internet of Things", Cisco Press, 2017, SAD

Big data tehnologije analize

Hadoop

- ❑ Uveden sa verzijom 2.0 Hadoop-a, YARN (*Yet Another Resource Negotiator*) je dizajniran da poboljša funkcionalnost MapReduce-a.
- ❑ Sa početnom verzijom, MapReduce je bio odgovoran za batch obradu podataka i praćenje poslova i upravljanje resursima u cijelom klasteru.
- ❑ YARN je razvijen da preuzme pregovaranje o resursima i praćenje poslova/zadataka, omogućavajući MapReduce-u da bude odgovoran samo za obradu podataka.
- ❑ Sa razvojem namenskog schedulera resursa klastera, Hadoop je u mogućnosti da doda dodatne module za obradu podataka svom osnovnom skupu karakteristika, uključujući interaktivni SQL i obradu u realnom vremenu, pored grupne obrade koristeći MapReduce.

Big data tehnologije analize

Hadoop ekosistem

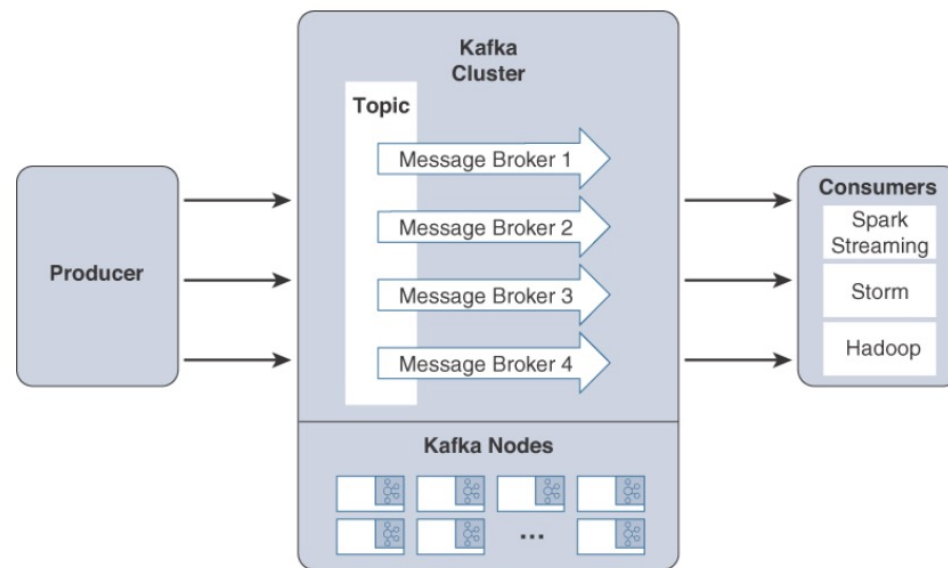
- ❑ Hadoop igra sve veću ulogu u prikupljanju, skladištenju i obradi IoT podataka zbog svoje visoko skalabilne prirode i svoje sposobnosti da radi s velikim količinama podataka.
- ❑ Mnoge organizacije su usvojile Hadoop klastere za skladištenje i obradu podataka i tražile su besplatne softverske pakete kako bi dodale dodatnu funkcionalnost svojim distribuiranim Hadoop klasterima.
- ❑ Od početne verzije Hadoop-a iz 2011. godine, razvijeni su mnogi projekti za dodavanje inkrementalne funkcionalnosti Hadoop-u i zajedno su postali poznati kao Hadoop ekosistem.
- ❑ Hadoop je možda imao oskudne početke kao sistem za distribuiranu pohranu i obradu, ali je od tada prerastao u robusnu kolekciju projekata koji stvaraju vrlo kompletan okvir za upravljanje podacima i analitiku.
- ❑ Hadoop obuhvata više od 100 softverskih projekata pod okriljem Hadoop-a, sposobnih za gotovo svaki element u životnom ciklusu podataka, od prikupljanja, preko skladištenja, do obrade, analize i vizualizacije.
- ❑ Svaki od ovih pojedinačnih projekata je jedinstveni dio cjelokupnog rješenja za upravljanje podacima.

Big data tehnologije analize

Hadoop ekosistem

Apache Kafka

- ❑ Deo obrade događaja u realnom vremenu, kao što su oni koji obično generišu pametni objekti, je njihovo unošenje u mašinu za obradu.
- ❑ Procesom prikupljanja podataka sa senzora ili log fajla, i pripreme za obradu i analizu obično upravljaju sistemi za razmjenu poruka.
- ❑ Sistemi za razmjenu poruka su dizajnirani da prihvate podatke ili poruke odakle se podaci generišu i isporučuju podatke sistemima za obradu toka kao što su Spark Streaming ili Storm.
- ❑ Apache Kafka je distribuirani sistem za razmjenu poruka između izdavača i pretplatnika koji je napravljen da bude skalabilan i brz.
- ❑ Sastoji se od *topic*-a ili brokera poruka, gdje proizvođači pišu podatke, a potrošači čitaju podatke iz ovih *topic*-a.



David Hanes, et al, "IoT Fundamentals: Networking Technologies, Protocols, and Use Cases for the Internet of Things", Cisco Press, 2017, SAD

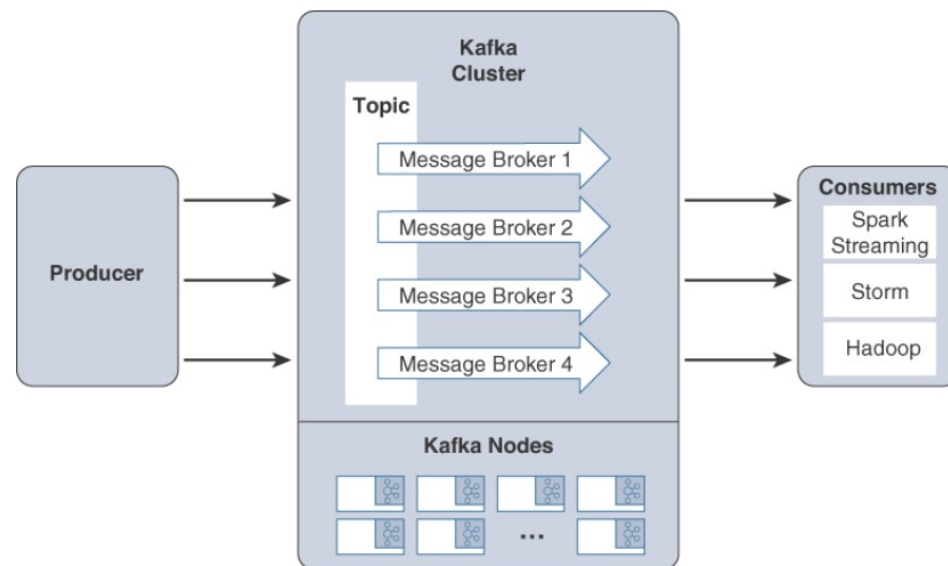
Big data tehnologije analize

Hadoop ekosistem

Apache Kafka

□ Zbog distribuirane prirode Kafke, može raditi u klaster konfiguraciji koja istovremeno rukuje mnogim proizvođačima i potrošačima i razmjenjuje informacije između čvorova, omogućavajući distribuciju *topic*-a na više čvorova.

□ Cilj Kafke je pružanje jednostavnog načina za povezivanje s izvorima podataka i omogućavanje potrošačima da se povežu s tim podacima na način na koji žele.



David Hanes, et al, "IoT Fundamentals: Networking Technologies, Protocols, and Use Cases for the Internet of Things", Cisco Press, 2017, SAD

Big data tehnologije analize

Hadoop ekosistem

Apache Storm i Apache Flink

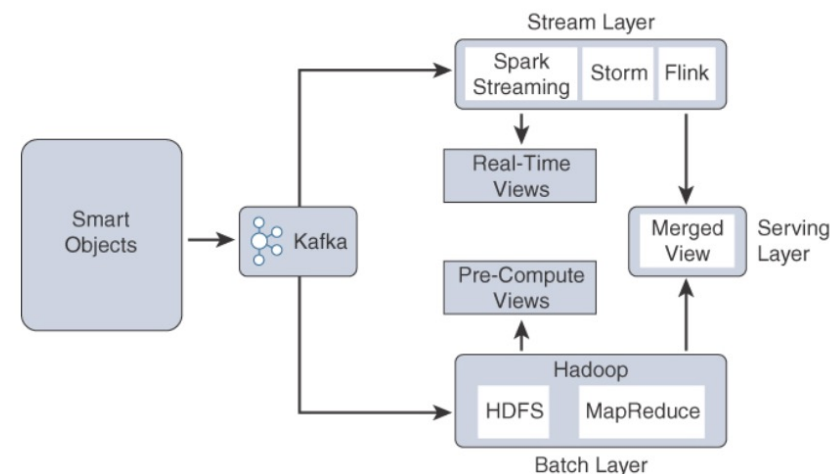
- ❑ Kada se koristi Hadoop ekosistem, mora se primijetiti da su različiti projekti vrlo slični i da se često značajno preklapaju s drugim projektima.
- ❑ To je slučaj sa mogućnostima prenosa podataka.
- ❑ Apache Spark se često koristi i za analizu distribuiranog streaminga i za *batch* obradu.
- ❑ Apache Storm i Apache Flink su projekti Hadoop ekosistema dizajnirani za distribuiranu obradu tokova i obično se koriste za slučajeve upotrebe IoT-a.
- ❑ Storm može povući podatke iz Kafke i obraditi ih na način skoro u realnom vremenu, kao i Apache Flink.
- ❑ Ovaj prostor se brzo razvija, a projekti će nastaviti da dobijaju i gube popularnost kako budu evoluirali.

Big data tehnologije analize

Hadoop ekosistem

Lambda arhitektura

- ❑ Ključni elementi data infrastrukture za podršku mnogim slučajevima korišćenja IoT-a uključuju prikupljanje, obradu i pohranu podataka korišćenjem više tehnologija.
- ❑ Upiti, podaci u pokretu (*streaming*) i podaci u mirovanju (*batch* obrada) zahtijevaju kombinaciju projekata Hadoop ekosistema.
- ❑ Jedna arhitektura koja se trenutno koristi za ovu funkcionalnost je Lambda arhitektura.
- ❑ Lambda je sistem za upravljanje podacima koji se sastoji od dva sloja za unos podataka (*Batch* i *Stream*) i jednog sloja za pružanje kombinovanih podataka (*Serving*).
- ❑ Ovi slojevi omogućavaju paketima kao što su Spark i MapReduce, da rade na podacima nezavisno, fokusirajući se na ključne attribute za koje su dizajnirani i optimizovani.
- ❑ Podaci se uzimaju od posrednika za poruke, obično Kafke, i obrađuju ih svaki sloj paralelno, a rezultirajući podaci se isporučuju u skladište podataka gdje se mogu pokrenuti dodatna obrada ili upiti.



David Hanes, et al, "IoT Fundamentals: Networking Technologies, Protocols, and Use Cases for the Internet of Things", Cisco Press, 2017, SAB

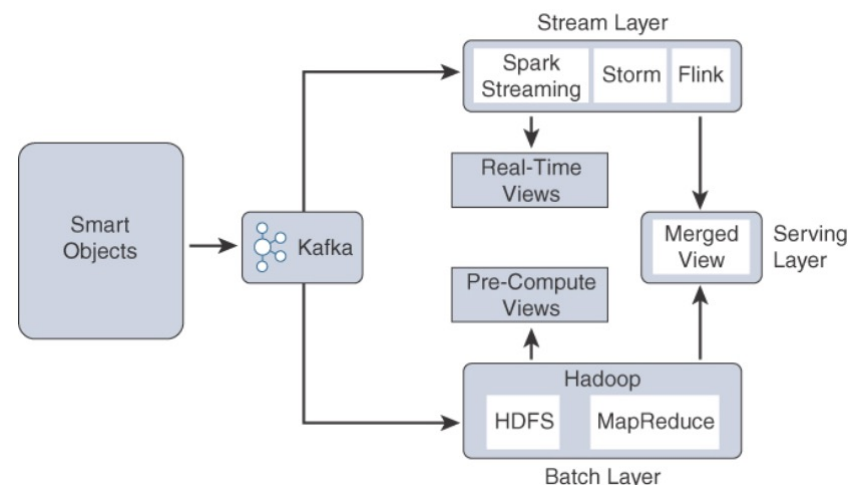
Big data tehnologije analize

Hadoop ekosistem

Lambda arhitektura

□ Lambda arhitektura nije ograničena na pakete u Hadoop ekosistemu, ali zbog svoje širine i fleksibilnosti, mnogi paketi u ekosistemu ispunjavaju zahtjeve svakog sloja:

- Sloj toka: Ovaj sloj je odgovoran za obradu događaja u realnom vremenu. Tehnologije kao što su Spark Streaming, Storm ili Flink se koriste za brzo unos, obradu i analizu podataka na ovom sloju. Upozorenje i automatizovane radnje mogu se pokrenuti na događaje koji zahtijevaju brzu reakciju ili mogu dovesti do katastrofalnih ishoda ako se ne riješe odmah.
- Batch sloj: Batch sloj se sastoji od mašine za grupnu obradu i skladišta podataka. Ako organizacija koristi druge dijelove Hadoop ekosistema za druge slojeve, MapReduce i HDFS mogu lako odgovarati. Druge tehnologije baza podataka, kao što su MPP, NoSQL ili warehouse, također mogu pružiti ono što je potrebno ovom sloju.
- Sloj za posluživanje: Sloj za posluživanje je skladište podataka i posrednik koji odlučuje koji od slojeva za unos podataka za upit na osnovu očekivanog rezultata ili pregleda podataka. Ako se traži zbirni ili istorijski prikaz, on može pozvati Batch sloj.
- Ako je potrebna analitika u realnom vremenu, ona može pozvati sloj Stream.
- Korisnici podataka često koriste sloj za posluživanje za pristup do oba sloja istovremeno



David Hanes, et al, "IoT Fundamentals: Networking Technologies, Protocols, and Use Cases for the Internet of Things", Cisco Press, 2017, SAD

Big data tehnologije analize

Hadoop ekosistem

Lambda arhitektura

- ❑ Lambda arhitektura može pružiti robustan sistem za prikupljanje i obradu ogromnih količina podataka i fleksibilnost u mogućnosti analiziranja podataka različitim brzinama.
- ❑ Jedno ograničenje ove vrste arhitekture je njeno mjesto u mreži.
- ❑ Zbog zahtjeva obrade i skladištenja mnogih od ovih dijelova, velika većina ovih implementacija je ili u data centru ili u cloud-u.
- ❑ Ovo bi moglo ograničiti efikasnost analize da odgovori dovoljno brzo ako su sistemi za obradu milisekunde ili sekunde udaljeni od uređaja koji generiše podatke.
- ❑ Distribuirana arhitektura za edge obradu može biti potrebna za povećanje infrastrukture centralnog data centra.

Analiza edge streaming aplikacija

- ❑ Glavno područje napretka IT-a u posljednjih nekoliko godina bio je prelazak na usluge u cloudu.
- ❑ Gotovo svaka velika tehnološka kompanija sada prodaje softver i usluge iz clouda, a to uključuje sisteme za analizu podataka, bilo da se nude kao usluga od javnog operatera u cloudu ili su izgrađeni u masivnim cloudima privatnih data centara.
- ❑ Analiza ogromne količine vremenski osjetljivih IoT podataka u centralizovanom cloudu često nije idealna.
- ❑ U svijetu IoT-a, ogromne količine podataka se generišu i često ih je potrebno analizirati uz trenutnu reakciju.
- ❑ Ne samo da je količina podataka generisanih na edge dijelu mreže ogromna - što znači da zahtjevi za propusnost za cloud ili data centar moraju biti projektovani tako da odgovaraju - već podaci mogu biti toliko vremenski osjetljivi da im je potrebna hitna reakcija i čekanje na analize u cloudu nije prihvatljivo.

Analiza edge streaming aplikacija

- ❑ Pojam big data se obično odnosi na nestrukturirane podatke koji su prikupljeni i pohranjeni u cloudu
- ❑ Podaci se prikupljaju tokom vremena kako bi se mogli analizirati pomoću alata za grupnu obradu, kao što su RDBMS, Hadoop ili neki drugi alat, čime se podaci valorizuju.
- ❑ Alati kao što su Hadoop i MapReduce su odlični u rješavanju problema koji zahtijevaju deep analizu na velikoj i složenoj količini nestrukturiranih podataka;
- ❑ Zbog njihove udaljenosti od krajnjih tačaka IoT-a i propusnog opsega potrebnog da se svi podaci vrate u cloud, oni nijesu dobro prilagođeni za analizu podataka u realnom vremenu.

Analiza edge streaming aplikacija

- ❑ U kontekstu IoT-a, uz streaming analizu koja se izvodi na edge čvorovima (bilo na samim sensorima ili vrlo blizu njih, u fog čvoru koji je, na primjer, integrisan u gateway-u), moguće je obraditi i djelovati na podatke u realnom vremenu bez čekanja na rezultate budućeg posla batch obrade u cloudu.
- ❑ Streaming analiza ne zamjenjuje big data analizu u cloudu jer obje imaju svoje uloge i doprinose poboljšanju poslovnih procesa.
- ❑ Ako se sirovi podaci generišu u data centru, ima smisla analizirati ih tamo.
- ❑ Ako se većina podataka generiše na udaljenim lokacijama pomoću senzora koji su rasprostranjeni po širokom području, da bi bili zaista efikasni u trenutku kada se kreiraju, podaci moraju biti analizirani i reakcije se moraju aktivirati što bliže edge-u.
- ❑ Nakon što se analiziraju i smanje na edge, rezultirajući podaci se mogu poslati u cloud i koristiti za sticanje dubljeg uvida tokom vremena.

Analiza edge streaming aplikacija

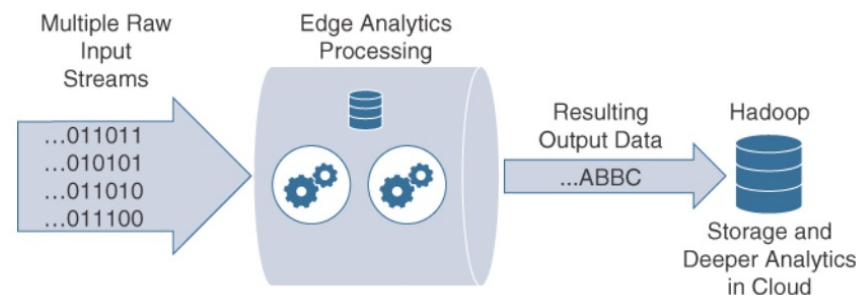
- ❑ Edge mreže je široko rasprostranjena, što znači da analitika na edge dijelu mreže mora biti visoko koordinirana i strukturirana.
- ❑ Prethodno podrazumijeva komunikacioni sistem u kome edge/fog čvorovi mogu komunicirati jedni s drugima kada je to potrebno i izvještaje o rezultatima slati velikom sistemu podataka u cloudu
- ❑ Iz poslovne perspektive, streaming analiza uključuje djelovanje na osnovu podataka koji se generišu dok su još vrijedni, prije nego što postanu zastarjeli.
- ❑ Na primjer, senzori puta u kombinaciji s GPS aplikacijama za pronalaženje puta mogu reći vozaču da izbjegava određeni put zbog saobraćaja, pri čemu su ovi podaci vrijedni samo za mali vremenski period.
- ❑ Istorijski gledano, može biti zanimljivo vidjeti koliko se saobraćajnih nesreća ili blokada dogodilo na određenom segmentu puta ili predvidjeti zastoje na osnovu prošlih podataka o saobraćaju.
- ❑ Međutim, za vozača u saobraćaju koji prima ovu informaciju, ako se po podacima ne postupi odmah, podaci imaju malu vrijednost.

Analiza edge streaming aplikacija

- ❑ Iz sigurnosne perspektive, trenutni pristup analiziranim i prethodno obrađenim podacima na edge dijelu mreže također omogućava kompaniji da shvati anomalije u svojoj mreži tako da se te anomalije mogu brzo korigovati prije nego što se prošire na ostatak mreže.
- ❑ Ključne vrijednosti edge streaming analitike uključuju sljedeće:
 - Smanjenje podataka na edge dijelu mreže: Zbirni podaci koje generišu IoT uređaji su proporcionalni broju uređaja tako da kako njihov broj može biti ogroman, samim tim i količina podataka koje generišu će biti ogromna. Prenos svih ovih podataka u cloud je neefikasno i nepotrebno je skupo u smislu propusnosti i mrežne infrastrukture.
 - Analiza i odgovor na edge dijelu mreže: Neki podaci su korisni samo na ivici pa ih je najbolje analizirati i djelovati tamo gdje su generisani.
 - Vremenska osjetljivost: Kada je potreban pravovremeni odgovor na podatke, prosljeđivanje podataka u cloud za buduću obradu rezultira neprihvatljivim kašnjenjem. Edge analitika omogućava trenutne odgovore na promjenljive uslove.

Analiza edge streaming aplikacija

- ❑ Za obavljanje edge analize, podatke je potrebno posmatrati kao tokove u realnom vremenu.
- ❑ Dok je analitika velikih podataka fokusirana na velike količine podataka u mirovanju, edge analiza neprekidno obrađuje tokove podataka u pokretu.
- ❑ Streaming edge analiza može se podijeliti u tri jednostavne faze:
 - Neobrađeni ulazni podaci: Ovo su sirovi podaci koji dolaze od senzora u jedinice za obradu.
 - Analitička procesorska jedinica (APU): APU filtrira i kombinuje tokove podataka (ili razdvaja tokove, po potrebi), organizuje ih po vremenskim prozorima i obavlja različite funkcije analize. U ovom trenutku na rezultate mogu djelovati mikro servisi koji rade u APU-u.
 - Izlazni tokovi: podaci koji izlaze organizovani su u tokove i koriste se za uticaje na ponašanje pametnih objekata i prosljeđuju se za storage i dalju obradu u cloudu. Komunikacija sa cloudom se često odvija putem standardnog protokola za razmjenu poruka izdavača/pretplatnika, kao što je MQTT.




David Hanes, et al, "IoT Fundamentals: Networking Technologies, Protocols, and Use Cases for the Internet of Things", Cisco Press, 2017, SAD

Analiza edge streaming aplikacija

- Da bi izvršio analizu u realnom vremenu, APU treba da izvrši sledeće funkcije:
 - Filtriranje: Podaci koji se generišu od strane IoT krajnjih tačaka vjerovatno će biti vrlo veliki, a većina njih je irelevantna. Na primjer, senzor može jednostavno anketirati na redovnoj osnovi kako bi potvrdio da je još uvijek dostupan. Ova informacija zapravo nije relevantna i uglavnom se može zanemariti. Funkcija filtriranja identifikuje informacije koje se smatraju važnima.
 - Transformacija: U svijetu warehousea podataka, operacije *Extract, Transform, and Load* (ETL) se koriste za manipulaciju strukturom podataka u formu koja se može koristiti u druge svrhe. Analogno ETL operacijama data warehousea, u streaming analizi, kada se podaci filtriraju, potrebno ih je formatirati za obradu.
 - Vrijeme: Kako tok podataka u realnom vremenu teče, potrebno je uspostaviti vremenski kontekst. Ovo bi moglo biti korelacija prosječne temperature očitavanja senzora svakog minuta. APU je programiran da izvještava prosječnu temperaturu svakog minuta od senzora, na osnovu prosjeka u protekle dvije minute. (Primjer gdje se ovo može koristiti je praćenje hrane u prodavnici u realnom vremenu, gdje treba pratiti prosjek temperature u otvorenim rashladnim jedinicama kako bi se osigurala sigurnost hrane.)

Analiza edge streaming aplikacija



□ Da bi izvršio analizu u realnom vremenu, APU treba da izvrši sledeće funkcije (nastavak):

- Korelacija: Streaming analiza podataka postaje najkorisnija kada se kombinuje više tokova podataka iz različitih tipova senzora. Na primjer, u bolnici se pacijentima mjeri nekoliko vitalnih znakova, uključujući tjelesnu temperaturu, krvni pritisak, broj otkucaja srca,.... Ovi različiti tipovi podataka dolaze iz različitih instrumenata, ali kada se ovi podaci kombinuju i analiziraju, oni pružaju neprocenjivu sliku zdravlja pacijenta u bilo kom trenutku. Korelacija nadilazi samo kombinovanje tokova podataka u realnom vremenu. Drugi ključni aspekt je kombinovanje i korelacija merenja u realnom vremenu sa već postojećim ili istorijskim podacima. Istorijski podaci mogu uključivati prošlu medicinsku istoriju pacijenta, kao što su rezultati analize krvi. Kombinovanje istorijskih podataka daje podacima uživo striminga moćan kontekst i promovise bolji uvid u trenutno stanje pacijenta.
- Obrasci podudaranja: Jednom kada su tokovi podataka pravilno očišćeni, transformisani i povezani s drugim tokovima u realnom vremenu, kao i istorijskim skupovima podataka, operacije podudaranja uzoraka se koriste za sticanje boljeg uvida u podatke. Na primjer, ako je APU već neko vrijeme prikupljao vitalne podatke pacijenta i uočio očekivane obrasce za svaku varijablu koja se prati, onda kada dođe do neočekivanog događaja, kao što je iznenadna promjena brzine otkucaja srca ili disanja, operater za usklađivanje obrasca to prepoznaje kao neuobičajeno i može preduzeti određene radnje, kao što je generisanje alarma za medicinsko osoblje. Obrasci mogu biti jednostavni odnosi, ili mogu biti složeni, na osnovu kriterijuma definisanih aplikacijom. Za identifikaciju ovih obrazaca može se koristiti mašinsko učenje.

Analiza edge streaming aplikacija

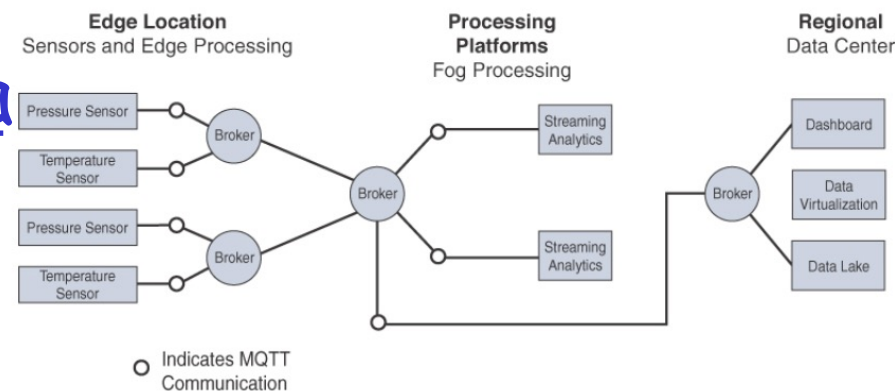
- Da bi izvršio analizu u realnom vremenu, APU treba da izvrši sledeće funkcije (nastavak):
 - Poboljšanje poslovne inteligencije: Vrijednost edge analize je u poboljšanjima poslovne inteligencije koja ranije nijesu bila dostupna. Sprovođenje edge analize o pacijentima u bolnici omogućava osoblju da brže odgovori na promjenjive potrebe pacijenata i takođe smanjuje količinu nestrukturiranih (i ne uvijek korisnih) podataka koji se šalju u cloud. Vremenom, rezultirajuće promjene u poslovnoj logici mogu proizvesti poboljšanja u osnovnim operacijama, donoseći viši nivo njege, kao i bolju efikasnost za bolnicu.

Analiza edge streaming aplikacija

- ❑ Zavisno od aplikacije i arhitekture mreže, analiza se može dogoditi u bilo kojem trenutku u cijelom IoT sistemu.
- ❑ Analiza se može izvoditi direktno na edge mreže, u fogu ili u cloud data centru.
- ❑ Ne postoje čvrsta i brza pravila koja određuju gdje treba raditi analizu, ali postoji nekoliko vodećih principa.
- ❑ Već je pomenuta važnost smanjenja podataka na edge mreže, kao i važnost analize informacija kako bi se na njih moglo odgovoriti prije nego što postanu zastarjeli.
- ❑ Značajno je i da se podaci povuku sa edge mreže da bi se dobio širi uvid na više podataka jer se ponekad može steći bolji uvid i inteligentnije reagovati na podatke kada se analizira širi skup podataka.

Analiza edge streaming aplikacija

- ❑ Fog analiza omogućava uvid u više od jednog uređaja, dajući vidljivost u agregaciji edge čvorova i omogućavajući povezivanje podataka iz šireg skupa.
- ❑ Iako postoji određena vrijednost u obavljanju analize direktno na edge čvorovima, senzori mogu komunicirati korišćenjem MQTT preko posrednika poruka do čvora za fog analizu, omogućavajući širi skup podataka.
- ❑ Fog čvor obavlja analizu tokova sa nekoliko edge uređaja, stičući bolji uvid zbog proširenog skupa podataka.
- ❑ Neće moći odgovoriti na događaj tako brzo kao u slučaju edge analize, ali je i dalje blizu da odgovori u realnom vremenu kako se događaji dešavaju. Kada fog čvor završi sa podacima, on saopštava rezultate u cloud (opet preko posrednika poruka preko MQTT-a) za deep analizu istorijskih podataka korišćenjem big data analitičke mehanizme.



David Hanes, et al, "IoT Fundamentals: Networking Technologies, Protocols, and Use Cases for the Internet of Things", Cisco Press, 2017, SAD

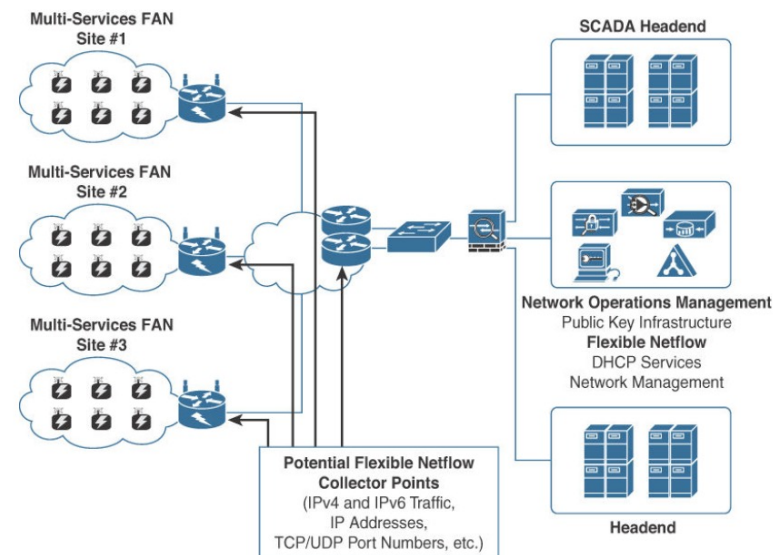
Mrežna analiza

- ❑ Drugi oblik analize koji je izuzetno važan u upravljanju IoT sistemima je mrežna analiza.
- ❑ Za razliku od prethodno razmatranih sistema za analizu podataka koji se bave pronalaženjem obrazaca u podacima generisanim od strane krajnjih tačaka, mrežna analiza se bavi otkrivanjem obrazaca u komunikacionim tokovima iz perspektive mrežnog saobraćaja.
- ❑ Mrežna analiza može da analizira detalje komunikacionih obrazaca napravljenih od strane protokola i da ih poveže u cijeloj mreži.
- ❑ Može se sagledati šta bi trebalo smatrati normalnim ponašanjem u mreži i brzo identifikovati anomalije koje ukazuju na probleme mreže zbog neoptimalnih puteva, malvera ili prevelikog zagušenja.
- ❑ Analiza obrazaca saobraćaja jedan je od najmoćnijih alata u arsenalu za rješavanje problema IoT mreže.

Mrežna analiza

❑ Krajnje tačke IoT-a, za razliku od generičkih računarskih platformi, dizajnirane su za direktnu komunikaciju sa vrlo malim brojem specifičnih servera aplikacija, kao što su IoT poruka ili broker podataka, ili specifični serveri aplikacija i sistemi za upravljanje mrežom.

- ❑ Ovo ponašanje predstavlja ključni aspekt koji se može iskoristiti prilikom izvođenja mrežne analize.
- ❑ Mrežna analiza nudi mogućnosti da se nosi s planiranjem kapaciteta za skalabilnu implementaciju IoT-a, kao i sigurnosni nadzor kako bi se otkrio nenormalan obim saobraćaja i obrasci (kao što je neuobičajen skok obima saobraćaja za normalno tihi protokol) i za centralizovane i za distribuirane arhitekture, kao što je *fog computing*.



David Hanes, et al, "IoT Fundamentals: Networking Technologies, Protocols, and Use Cases for the Internet of Things", Cisco Press, 2017, SAB

Mrežna analiza

- ❑ IoT uređaj šalje svoj saobraćaj određenim serverima, bilo direktno aplikaciji ili IoT brokeru s korisnim opterećenjem podataka inkapsuliranim u datom protokolu.
- ❑ Time se par izvorišnih i odredišnih adresa, kao i brojevi TCP ili UDP portova, mogu koristiti za mrežnu analizu.
- ❑ Jedan od pokretača usvajanja IP za IoT je korišćenje alata i procesa koji su u velikoj mjeri poznati i implementirani od strane ISP i kompanijskih mreža.
- ❑ Da bi se nadgledala mrežna infrastruktura, de facto industrijski standardi i protokoli omogućavaju sveobuhvatnu karakterizaciju tokova IP saobraćaja, uključujući identifikaciju izvorišnih i/ili odredišnih adresa, tajming podataka i obim, i tipove aplikacija unutar mrežne infrastrukture.
- ❑ Statistika tokova se može prikupljati na različitim lokacijama u mreži (ruteri, switch-evi,...)
- ❑ Nakon što se podaci prikupe u poznatom formatu, mogu se poslati na eksterne alate za mrežnu analizu koji pružaju usluge mrežnom menadžmentu, poput sigurnosti, praćenja performansi i planiranja.

Mrežna analiza

□ Prednosti analize tokova, pored ostalih usluga upravljanja mrežom, su sljedeće:

- Nadgledanje i profilisanje mrežnog saobraćaja: Prikupljanje tokova sa mrežnog nivoa pruža globalne i distribuirane mogućnosti praćenja u skoro realnom vremenu. IPv4 i IPv6 analiza saobraćaja i obrazaca širom mreže pomaže administratorima da proaktivno otkriju i brzo otklone probleme kada se pojave.
- Praćenje i profilisanje saobraćaja aplikacija: Nadgledanje i profilisanje se mogu koristiti za dobijanje detaljnog vremenskog uvida o uslugama pristupa IoT-u, kao što su protokoli na nivou aplikacije, uključujući MQTT, CoAP i DNP3, kao i pridružene aplikacije koje se trenutno koriste preko mreže.
- Planiranje kapaciteta: Analiza toka se može koristiti za praćenje i predviđanje rasta IoT saobraćaja i pomoći u planiranju nadogradnje prilikom postavljanja novih lokacija ili usluga analizom snimljenih podataka tokom dužeg vremenskog perioda. Ova analiza pruža priliku za praćenje i predviđanje kontinualnog rasta IoT mreže.
- Sigurnosna analiza: Budući da većina IoT uređaja obično generiše mali obim saobraćaja i uvijek šalje svoje podatke na isti server(e), svaka promjena ponašanja mrežnog saobraćaja može ukazivati na događaj ugrožavanja cyber sigurnosti, kao što je DoS napad. Sigurnost se može nametnuti osiguravanjem da se saobraćaj ne šalje izvan opsega IoT domena. Na primjer, sa LoRaWAN gateway-om, ne bi trebalo biti razloga da se javlja saobraćaj poslat ili primljen van LoRaWAN mrežnog servera i sistema za upravljanje mrežom. Takav saobraćaj može ukazivati na neku vrstu napada.

Mrežna analiza

- Prednosti analize tokova, pored ostalih usluga upravljanja mrežom, su sljedeće (nastavak):
 - Računovodstvo: U terenskim mrežama, ruteri ili gateway-i su često fizički izolovani i koriste javne mobilne usluge i VPN-ove za prenos preko okosnice. Implementacije mogu imati hiljade gateway-a koji povezuju IoT infrastrukturu pritupne mreže preko mobilne mreže. Praćenje toka se stoga može iskoristiti za analizu i optimizaciju naplate, zajedno sa drugim namenskim aplikacijama, kao što je Cisco Jasper, sa širim opsegom nego samo praćenje toka podataka.
 - Data warehousing and data mining: Podaci o toku (ili izvedene informacije) mogu se skladištiti za kasniju analizu kao podršku proaktivnoj analizi multiservisnih IoT infrastruktura i aplikacija.

Mrežna analiza

Flexible NetFlow arhitektura

- ❑ Flexible NetFlow (FNF) i IETF IPFIX (RFC 5101, RFC 5102) su primjeri protokola koji se široko koriste u mrežama.
- ❑ FNF je tehnologija toka koju je razvio Cisco i koja je široko rasprostranjena širom svijeta.
- ❑ Ključne prednosti FNF-a su sljedeće:
 - Fleksibilnost, skalabilnost i agregacija podataka o toku
 - Sposobnost praćenja širokog spektra informacija o paketima i generisanje novih informacija o ponašanju mreže
 - Poboljšana detekcija mrežnih anomalija i sigurnosti
 - Informacije o toku koje može konfigurirati korisnik za izvođenje prilagođene identifikacije saobraćaja i mogućnost fokusiranja i praćenja specifičnog ponašanja mreže
 - Konvergencija više računovodstvenih tehnologija u jedan računovodstveni mehanizam

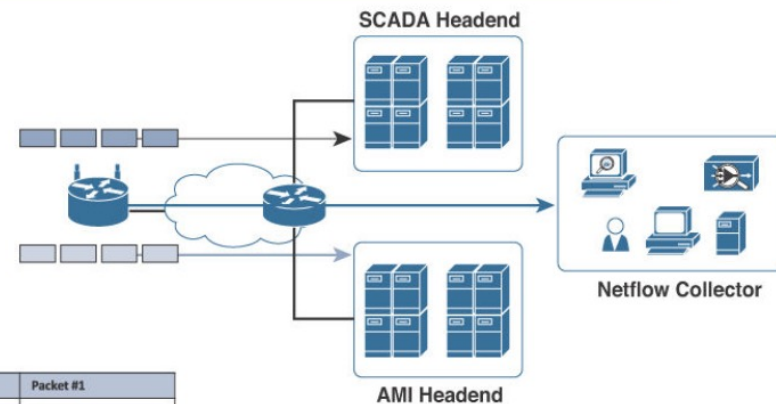
Mrežna analiza

Flexible NetFlow arhitektura

FNF Flow Monitor (NetFlow cache):

- ❑ FNF Flow Monitor opisuje NetFlow cache ili informacije pohranjene u keš memoriji.
- ❑ Flow Monitor sadrži definicije zapisa toka sa ključnim poljima (koriste se za kreiranje toka, jedinstveni po zapisu toka: izjava podudaranja) i poljima koja nisu ključna (sakupljena sa tokom kao atributima ili karakteristikama toka) unutar keša.
- ❑ Dio Flow Monitora je Flow Exporter, koji sadrži informacije o exportu NetFlow informacija, uključujući odredišnu adresu NetFlow kolektora.
- ❑ Flow Monitor uključuje različite karakteristike keša, uključujući tajmere za export, veličinu keša i, ako je potrebno, brzinu uzorkovanja paketa.

First packet of a flow will create the Flow entry using the Key Fields
Remaining packets of this flow will only update statistics (bytes, counters, timestamps)



Key Fields	Packet #1
Source IP	2001:d8b:1:2::68
Destination IP	2001:d8b:3:4:250
Source Port	27356
Destination Port	4059
Layer 3 protocol	17
TOS byte	0
Ingress interface	WPAN 0
Non-Key Fields	
Length	512
Packets count	23

← FNF Flows →

Key Fields	Packet #2
Source IP	192.168.27.1
Destination IP	10.23.42.56
Source Port	45324
Destination Port	20000
Layer 3 protocol	6
TOS byte	0
Ingress interface	Ethernet 0
Non-Key Fields	
Length	768
Packet counts	23

FNF Cache

Src. IP	Dest. IP	Src. Port	Dest. Port	Layer 3 Prot.	TOS Byte	Ingress Intf.	Timestamps	Length	Packets
2001-d8b:1:2::68	2001-d8b:3:4:250	27356	4059	17	0	Wpan 0		512	23
192.168.27.1	10.23.42.56	45324	20000	6	0	Ethernet 0		768	35

David Hanes, et al, "IoT Fundamentals: Networking Technologies, Protocols, and Use Cases for the Internet of Things", Cisco Press, 2017, SAD


Mrežna analiza

Flexible NetFlow arhitektura

FNF Flow record

- Flow record je skup ključnih i neključnih vrijednosti polja NetFlow koji se koriste za karakterizaciju tokova u NetFlow kešu.
- Zapisi toka mogu biti unaprijed definisani radi lakšeg korišćenja ili prilagođeni i korisnički definisani.
- Tipičan unaprijed definisani zapis agregira podatke o toku i omogućava korisnicima da ciljaju uobičajene aplikacije za NetFlow.
- Korisnički definisani zapisi omogućavaju izbor specifičnih ključnih ili neključnih polja u zapisu toka.
- Korisnički definisano polje je ključ za Flexible NetFlow, omogućavajući NetFlow-u da karakteriše i eksportuje širok spektar informacija.

First packet of a flow will create the Flow entry using the Key Fields
Remaining packets of this flow will only update statistics (bytes, counters, timestamps)



Key Fields	Packet #1
Source IP	2001:d8b:1:2::68
Destination IP	2001:d8b:3:4:250
Source Port	27356
Destination Port	4059
Layer 3 protocol	17
TOS byte	0
Ingress Interface	Wpan 0
Non-Key Fields	
Length	512
Packets count	23

Key Fields	Packet #2
Source IP	192.168.27.1
Destination IP	10.23.42.56
Source Port	45324
Destination Port	20000
Layer 3 protocol	6
TOS byte	0
Ingress Interface	Ethernet 0
Non-Key Fields	
Length	768
Packets counts	23

FNF Flows

FNF Cache

Src. IP	Dest. IP	Src. Port	Dest. Port	Layer 3 Prot.	TOS Byte	Ingress Intf.	Timestamps	Length	Packets
2001:d8b:1:2::68	2001:d8b:3:4:250	27356	4059	17	0	Wpan 0		512	23
192.168.27.1	10.23.42.56	45324	20000	6	0	Ethernet 0		768	35

David Hanes, et all, "IoT Fundamentals: Networking Technologies, Protocols, and Use Cases for the Internet of Things", Cisco Press, 2017, SAD


Mrežna analiza

Flexible NetFlow arhitektura

FNF Exporter

- Postoje dvije primarne metode za pristup NetFlow podacima: korišćenje naredbi show na interfejsu komandne linije (CLI) i korišćenje alata za izvještavanje aplikacije.
- NetFlow Export, za razliku od SNMP anketiranja, periodično šalje informacije u NetFlow reporting collector.
- Flexible NetFlow Exporter omogućava korisniku da definiše gdje se eksport može poslati, tip transporta za eksport i svojstva za eksport.
- Po Flow monitoru može se konfigurirati više eksportera.

First packet of a flow will create the Flow entry using the Key Fields
Remaining packets of this flow will only update statistics (bytes, counters, timestamps)



Key Fields	Packet #1
Source IP	2001:d8b:1:2::68
Destination IP	2001:d8b:3:4:250
Source Port	27356
Destination Port	4059
Layer 3 protocol	17
TOS byte	0
Ingress Interface	WPAN 0
Non-Key Fields	
Length	512
Packets count	23

← FNF Flows →

Key Fields	Packet #2
Source IP	192.168.27.1
Destination IP	10.23.42.56
Source Port	45324
Destination Port	20000
Layer 3 protocol	6
TOS byte	0
Ingress Interface	Ethernet 0
Non-Key Fields	
Length	768
Packet counts	23

FNF Cache

Src. IP	Dest. IP	Src. Port	Dest. Port	Layer 3 Prot.	TOS Byte	Ingress Intf.	Timestamps	Length	Packets
2001:d8b:1:2::68	2001:d8b:3:4:250	27356	4059	17	0	Wpan 0		512	23
192.168.27.1	10.23.42.56	45324	20000	6	0	Ethernet 0		768	35

Mrežna analiza

Flexible NetFlow arhitektura

Tajmeri za eksport toka:


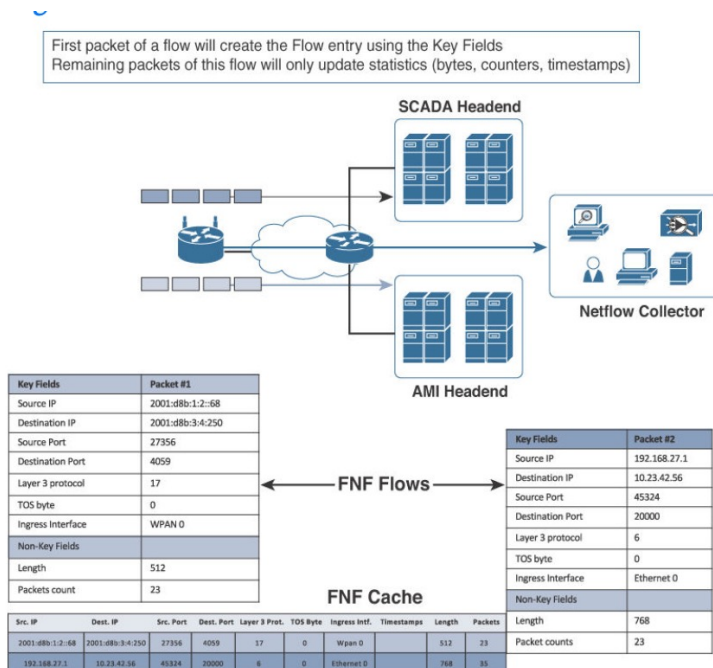
- Tajmeri pokazuju koliko često tokove treba eksportovati na server za prikupljanje i izvještavanje.

NetFlow format eksporta:

- Ovo jednostavno ukazuje na tip formata za izvještavanje o toku.

NetFlow server za prikupljanje i izvještavanje

- Ovo je odredište eksporta toka. Često se radi pomoću analitičkog alata koji traži anomalije u obrascima saobraćaja.



Analiza IoT podataka

Mrežna analiza

Flexible NetFlow arhitektura

- ❑ U kontekstu multiservisnih IoT mreža, preporučuje se da se FNF konfiguriraju na ruterima koji agregiraju veze s rutera pristupne mreže.
- ❑ Ovo daje globalni pogled na sve usluge koje teku između osnovne mreže u cloudu i IoT pristupne mreže (iako ne između samih IoT uređaja).
- ❑ FNF se također konfiguriraju na izlazu pristupne mreže ili fog čvorovima kako bi se pružila bolja vidljivost.
- ❑ Mora se voditi računa o tome koliko northbound podataka se troši kroz izvještavanje.
- ❑ Analiza protoka na gateway-u nije moguća sa svim IoT sistemima.
- ❑ Na primjer, LoRaWAN gateway-i jednostavno prosljeđuju saobraćaj senzora MAC sloja na centralizovani LoRaWAN mrežni server, što znači da analiza toka (bazirana na sloju 3) u ovom trenutku nije moguća.
- ❑ Sličan problem se javlja kada se koristi MQTT server koji šalje podatke preko IoT brokera.

Mrežna analiza

Flexible NetFlow arhitektura

- Neki drugi izazovi s implementacijom alata za analizu toka u IoT mreži uključuju sljedeće:
 - Distribuirana priroda fog i edge computing-a može značiti da se saobraćajni tokovi obrađuju na mjestima koja možda ne podržavaju analizu toka, pa se na taj način gubi vidljivost.
 - IPv4 i IPv6 interfejsi ponekad moraju pregledati pakete unutar VPN tunela, što može uticati na performanse rutera.
 - Dodatni saobraćaj upravljanja mrežom generišu FNF uređaji za izvještavanje. Dodatno povećanje iskorišćenja propusnog opsega treba preispitati, posebno ako backhaul mreža koristi celularne ili satelitske komunikacije.