

TEKOÄLY LOGISTIIKASSA

SSI SCHÄFER
Whitepaper

LOKAKUU
2018

Käsitteet, sovellukset ja tulevaisuudennäkymät

ssi-schaefer.com



AI

SSI SCHÄFER

SISÄLLYS

- 1_ Johdanto
 - 2_ Tekoälyyn liittyviä peruskäsitteitä
 - 2.1 Tekoäly
 - 2.2 Koneoppiminen
 - 2.2.1 Ohjattu oppiminen
 - 2.2.2 Ohjaamaton oppiminen
 - 2.2.3 Puoliohjattu oppiminen
 - 2.2.4 Vahvistusoppiminen
 - 2.3 Syväoppiminen
 - 2.3.1 Neuroverkkojen peruseriaatteen
 - 2.4 Kognitiivinen tietojenkäsittely
 - 3_ Tekoäly logistiikassa
 - 3.1 Simulointi
 - 3.2 Optimointi
 - 3.2.1 Hitachi ja H: Tekoäly antaa ohjeita varastotyöntekijöille
 - 3.2.2 Zalando: Reittien optimointia syväoppimisen avulla
 - 3.2.3 Tekoäly ja itseohjautuvat robotit
 - 3.3 Ennakoiva analytiikka
 - 3.3.1 Otto: Palautukset vähenivät kahdella miljoonalla tekoälyn avulla
 - 3.3.2 Zalando: Oma kauppa jokaiselle asiakkaalle
 - 3.3.3 Tekoälyä ilmassa
 - 3.4 Ennustavasta kunnossapidosta ennakoivaan kunnossapitoon
 - 4_ Yhteenveto: Kuinka tekoäly muuttaa arvoketjua
 - 5_ SSI SCHÄFERin lähestymistapa
- Lähteet




Tekoäly oli vuoden 2017 eniten hehkutettu konsepti. Supertietokone, joka päihitti go-pelin maailmanmestarin, Sirin ja Alexan kaltaiset älykkäät avustajat, jotka antavat (usein) järkeviä vastauksia puhuen esitettyihin kysymyksiin sekä lukuisat muut sovellukset ovat kaikki osoituksia siitä, kuinka valtava potentiaali tekoälyllä jo on.

Tekoäly nousi monien aikakausi- ja bisneslehtien etusivun aiheeksi. Usein vaikuttaa siltä, että teknologia ei ole pelkästään riittävän kehittynyt korvaamaan ihmisiä monissa osaamista vaativissa tehtävissä, vaan jopa suoriutumaan ihmisiä paremmin, kun asiaa tarkastellaan teknisen suorituskyvyn kannalta. Monet alan asiantuntijat kuitenkin myöntävät, että tekoälyn kehitys on vasta alkuvaiheessa, mitä tulee operatiivisen logistiikan sovelluksiin. Jos sitä muutama vuosi sitten voitiin verrata pikkulapseen, joka osasi tehdä yksinkertaisia erotteluita ("äiti", "isä"), se on nyt kasvanut teini-ikäiseksi, jolle voidaan uskoa monimutkaisempia tehtäviä niihin liittyvine ohjeineen.

Lisäksi monia erikoisalan termejä, kuten tekoäly, koneoppiminen, syväoppiminen tai hermoverkot, käytetään usein toistensa synonyymeina ja ilman selkeää jaottelea, mikä aiheuttaa maallikolle jossain määrin hämmennystä näiden käsitteiden merkityksestä.

Tämä asiantuntijaraportti pyrkii tarjoamaan yksiselitteiset määritelmät tekoälyyn liittyville käsitteille ja menetelmille sekä pohtimaan sitä, mille alueille tekoäly nykyvaiheessaan soveltuu ja millaisia näköaloja tekoälyteknologiat avaavat logistiikassa.



PYSTYVÄTKÖ KONEET AJATTELEMAAN?

Helppo kysymys, johon on vaikea vastata. Eri tutkijat määrittelevät jo käsitteet ”ajattelu” ja ”älykkyys” toisistaan poikkeavilla tavoilla. Tämä on vain yksi ongelmista, joihin törmätään, kun aletaan tarkemmin tarkastella tekoälyä.

Vaikka tekoälyjärjestelmät pystyvät käsittelemään paljon suurempia määriä dataa – ja siis tietoa – kuin ihmiset, niiden puutteena on tähän asti ollut se, että ne pystyvät valitsemaan vain ennalta tunnetuista päätösvaihtoehdoista. Innovatiivinen ja luova ajattelu on ihmisten ainutlaatuinen ominaisuus.

Yksi asia on selvä: algoritmikehityksen viimeaikainen edistyminen, kasvanut prosessointiteho ja saatavilla olevan datan määrän eksponentiaalinen kasvu tarkoittavat, että nykyisin on mahdollista kehittää järjestelmiä, jotka pystyvät suorittamaan tehtäviä, joihin vain ihmisen on aikaisemmin ajateltu kykenevän. Sen lisäksi järjestelmät suorittavat noita tehtäviä usein ihmistä täsmällisemmin, horjumattomalla luotettavuudella ja kellon ympäri taukoja tarvitsematta.

Itseoppivat järjestelmät suorittavat asiakaspalvelutehtäviä, hallinnoivat logistiikan prosesseja, analysoivat lääketieteellisiä tietoja tai kirjoittavat viestejä ja säveltävät musiikkia. Koneoppimisen osa-alueessa syväoppimisessa hyödynnetään usean kerroksen neuroverkkoja – juuri tämän rakenteen johdosta menetelmän nimessä on ”syvä”-etuliite. Syväoppiminen laajentaa tekoälyn mahdollisuuksia monimutkaisempiin tehtäviin, joissa tarvitaan monivaiheista laskentaa.

Koneet pystyvät nykyisin tunnistamaan monitahoisen tarkasti esineitä ja kasvoja, voittamaan ihmisiä shakin ja gon kaltaisissa vaativissa peleissä, lukemaan huulilta ja tuottamaan jopa luonnollista puhetta. Monet yritykset – SSI SCHÄFER mukaan lukien – pitävät tekoälyä strategiansa keskeisenä osana ja tulevan ydinliiketoimintansa kriittisenä tekijänä.

Yhtäältä tekoäly voi tarjota perustan valtavalle tuottavuuden kasvulle ja elämänlaadun paranemiselle. Toisaalta, kuten uusien teknologioiden kanssa aina on, se voi johtaa radikaaliin työelämän muutokseen, jota voidaan verrata liukuhihnan käyttöönottoon. kaikista niistä eettisistä ja yhteiskunnallisista seikoista puhumattakaan, joita meidän on pohdittava, jos koneiden älyllinen kapasiteetti kasvaa kasvamistaan. ■

Se, mikä ennen kuului tieteiskirjallisuuteen, on nyt todellisuutta. ”Koneoppimisessa” hyödynnetään tietoa, joka sisältyy tietokantoihin ja tietovarastoihin, ja koulutusvaiheen jälkeen kone pystyy antamaan täsmällisiä suosituksia päätöksenteolle.



TEKOÄLYYN LIITTYVIÄ PERUSKÄSITTEITÄ

2.1 TEKOÄLY

Tekoäly on tietojenkäsittelyn osa-alue, joka keskittyy älykkään toiminnan automatisointiin. Tekoälyssä tavoitteena on ohjelmoida tietokone siten, että se kykenee käsittelemään ongelmia itsenäisesti, samaan tapaan kuin asianmukaisesti koulutettu ihminen tekisi. Ongelmanratkaisu tarkoittaa sellaisten päätösten tekoa, joilla voidaan muodostaa asianmukainen vaste käsillä olevaan ongelmaan tietyn ajan puitteissa erilaisia tietolähteitä hyödyntämällä (tietokannat, anturit, videokamerat jne.).

Perinteiset tietokoneohjelmat toimivat siten, että kehittäjät koodaavat ohjelmaan tarkat ohjeet, joiden mukaan ohjelman tulee suorittaa tehtävät. Tämä toimii hyvin monissa tilanteissa, jotka voidaan määritellä hyvin tarkasti, mutta tietyn kompleksisuustason jälkeen törmätään rajoituksiin. Ihmisohjelmoijan ei ole mahdollista koodia laatiessaan ottaa huomioon kaikkia mahdollisia tulevia käyttötappauksia. Jos ympäristö muuttuu, ohjelmat eivät enää pysty saavuttamaan haluttuja tavoitteita tai haluttua suorituskykyä, koska taustaehtot ovat muuttuneet merkittävästi.

Koneoppimista alettiin kehittää tämän ongelman ratkaisemiseksi: sitä soveltava kone perustuu mukautuviin eli adaptiivisiin algoritmeihin, jotka pystyvät oppimaan tietoi-
neistosta eivätkä ole riippuvaisia sääntöpohjaisesta ohjelmoinnista. Järjestelmä pystyy tunnistamaan toistuvia malleja, yhdistelemään tietoja ja luomaan käsityksiä käytettävissä olevan datan pohjalta. On siis kyse yleisesti merkityksellisten yhteyksien luomisesta syöte- ja tulosaineiston välille tekoälyn avulla.

Tämäntyyppinen oppiminen edellyttää paljon prosessointitehoa ja riittävän suurta datan määrää. Big data on tuonut molemmat näistä edellytyksistä saatavilla vasta äskettäin, joten ei ole mikään ihme, että koneoppiminen on kehittynyt valtavasti juuri viime vuosina. ▶

Vielä noin kymmenen vuotta sitten tekoälytutkimuksen tavoite oli toisintaa ihmisen älykkyys koneissa. Tämä nosti esiin monia ongelmia, joista yksi on kysymys, mitä me oikeastaan tarkoitamme käsitteellä "älykkyys". Älykkyuden määritelmän vähimmäisvaatimuksiksi katsottiin viisi kykyä, jotka ovat:

- havaintojen teko
- johtopäätösten teko
- oppiminen
- ongelmien ratkaiseminen
- kielellinen älykkyys.

Ihmisen älykkyys on toki paljon muutakin kuin näitä, mutta keskittyminen viiteen keskeiseen älykkyyden kykyyn johti suureen harppaukseen tekoölyn tutkimuksessa. Sen sijaan, että oltaisiin yritetty ohjelmoida ihmisten osoittamaa ”yleisälykkyyttä”, tarkastelukulma siirtyi tarkasti määriteltäviin tehtäviin.

Tekoöly ei ole enää perustutkimuksen tasolla, vaan siitä on tullut osa jokapäiväistä elämäämme. Enää ei monilla aloilla voitaisi edes ajatella työn tekemistä ilman tekoölyteknologioita, olipa sitten kyse Applen Sirin ja Amazonin Alexan käyttämisestä puheentunnistusalgoritmeista, lääketieteellisten löydösten tulkinnasta, valvontakameranauhoitusten kasvojen tunnistuksesta tai farmakologisesta tutkimuksesta. ■

2.2 KONEOPPIMINEN

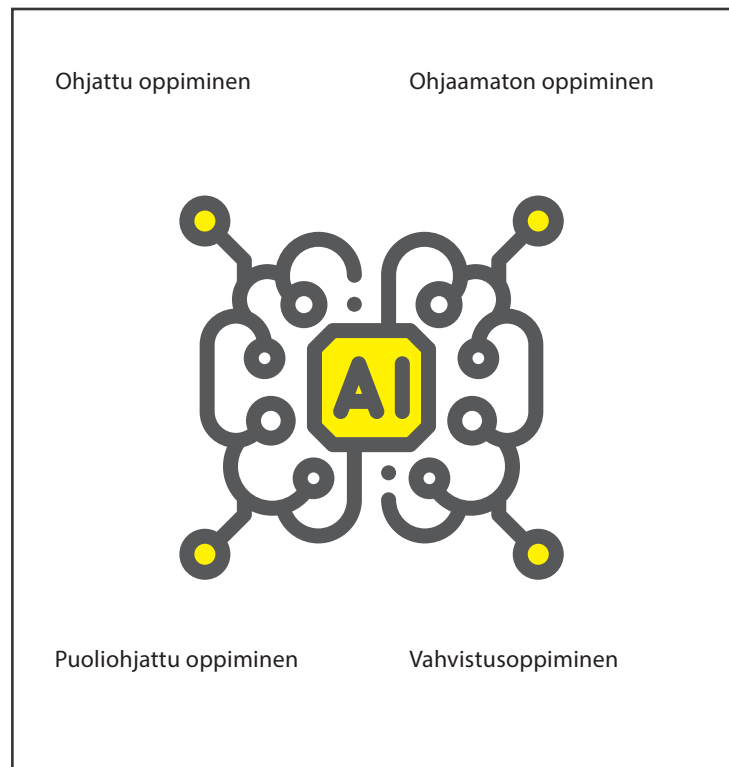
Koneoppiminen on yleiskäsite, jolla tarkoitetaan erilaisia prosesseja, joiden avulla pyritään selvittämään syöte- ja tulostietojen välinen tuntematon funktionaalinen suhde. Edelleen tärkeiden perinteisten menetelmien, kuten klusterinmuodostuksen, regression sekä tekijä- ja aikasarja-analyysien, lisäksi se hyödyntää monimutkaisempia menetelmiä, kuten hermoverkkoja, evolutionääristä laskentaa ja tukivektorikoneita.

Perusmuodossaan koneoppimisalgoritmit syötetään tietoa, joka sen pitää analysoida ja tunnistaa, jotta saadaan tietty lopputulos. Yksi esimerkki on roskapostin luokittelu, jota käyttävät lähes kaikki suuret sähköpostipalveluntarjoajat: Ohjelmalle annetaan tuhansia sähköposteja, jotka on luokiteltu joko ”roskapostiksi” tai ”ei-roskapostiksi”. Näin algoritmi ”oppii” tunnistamaan roskaposteja tunnistamalla tiettyjä elementtejä, joiden mukana olo erottaa roskapostin asiallisista sähköposteista.

Algoritmit siis yrittävät löytää toistuvia malleja olemassa olevista tietokannoista ja luokittelevat tietoja tai tekevät ennusteita niiden mallien pohjalta. Muita esimerkkejä ovat verkkoalustojen musiikki- tai ostosuosituksien sekä markkinointikampanjojen tai asiakaspalvelun optimointi.

Tässä oikeiden mallien johtaminen on äärimmäisen tärkeää, sillä tietokannoista voidaan lähes aina löytää toistuvia malleja, jotka voidaan linkittää muihin tapahtumiin. Ovatko nämä mallit ja linkitykset mielekkäitä jonkin tietyn ongelman ratkaisuun, on jo toinen kysymys. ■

Algoritmien käyttämät oppimisstrategiat jaetaan yleensä neljään pääluokkaan, jotka ovat:



2.2.1 OHJATTU OPPIMINEN

Ohjattu oppiminen on selvästi yleisimmin sovellettu koneoppimistapa. Siinä algoritmilta annetaan syöteaineisto (esim. kuvia) yhdessä toivotun tulosaineiston (luokka) kanssa.

Esimerkki: Jos tietokoneen halutaan erottelvan kissoja ja koiria sisältävät kuvat, sille annetaan satoja kissojen ja koirien kuvia hyvin monista eri kuvakulmista, ja kunkin kuvan yhteydessä ilmoitetaan luokka "KISSA" tai "KOIRA". Tällä tavoin algoritmin odotetaan kehittävän säännön, jonka pohjalta se pystyy jatkossa erottelemaan koirat ja kissat helposti toisistaan. Oppimisalgoritmin tulee myös olla abstrakti tai pystyä tekemään yleistyksiä opetusaineiston pohjalta. Oppimisessa saattaa tapahtua "ylišovittamista", mikä tarkoittaa, että olemassa oleva digitaalinen tieto hämärtyy syötteessä olevan liiallisen datan myötä. Tätä oppimisstrategiaa on käytetty jo useita vuosia sovelluksissa, joissa kameraa käytetään viivakoodien tai datamatriisikoodien tunnistamiseen ja lukuun perinteisen laserlukijan sijaan. ■

2.2.2 OHJAAMATON OPPIMINEN

Ohjaamattomassa oppimisessa algoritmi pyrkii löytämään soveltuvia malleja pelkästään syöteaineistoa tarkastelemalla ja tiivistämään reaali-maailman valtavan datamäärän ulottuvuuksia ja kompleksisuutta, ilman että merkittävää tietoa juurikaan katoaa. On selvää, että tällainen vailla selvää tavoitetta suoritettava tehtävä on paljon monimutkaisempi. ■

2.2.3 PUOLIOHJATTU OPPIMINEN

Puoliohjattu oppiminen on kahden yllä mainitun prosessin yhdistelmä. Tämä tarkoittaa, että luokitellun datan tunnistamisen lisäksi samanaikaisesti suoritetaan ulottuvuuksien tiivistämistä, jotta päästään nopeampaan, tehokkaampaan ja mahdollisesti kattavampaan tunnistukseen. ■



2.2.4 VAHVISTUSOPPIMINEN

Vahvistusoppimisessa algoritmi oppii itsenäisesti parhaan strategian jonkin tavoitteen saavuttamiseksi tulevaisuudessa. Algoritmilta ei anneta oikeaa lopputulosta, mutta sille annetaan palautetta (vahvistus) siitä, onko algoritmi lähestymässä sille asetettua tavoitetta vai etääntymässä siitä. Syviin neuroverkkoihin perustuvat vahvistusoppimisalgoritmit ("syvä vahvistusoppiminen") ovat osoittautuneet erityisen menestyksekkäiksi tässä tehtävässä.

Neuroverkko löytää datasta toistuvia malleja ja kehittää niiden pohjalta mallin tietoaaineiston kuvaamasta maailman osasta. Algoritmilta ei anneta opetusaineistoa, vaan se hankkii datan ympäristön vuorovaikutuksen ja palautteen kautta. Tämä menetelmä soveltuu erityisen hyvin luokitteluun, ennustamiseen ja tuotantoon liittyvien ongelmien käsittelyyn. ▶

Vahvistusoppimista käytetään tapauksissa, jossa myös tavoitteen saavuttamisen reitillä on merkitystä eikä tarkkaa tietoa lopputuloksesta ole saatavilla, vaan lopputulos arvioidaan suhteessa aiempaan tietämyspohjaan.

Koneoppimisella voidaan ratkaista luokittelu-, ennustamis- ja tuottamisongelmia

Luokittelu	Visuaalisten kohteiden luokittelu tai varustaminen tunnisteilla	Esineiden ja kasvojen tunnistaminen kuvista ja videoista
	Kirjoituksen ja tekstin luokittelu tai varustaminen tunnisteilla	Kirjainten, symbolien ja sanojen tunnistaminen näytteestä
	Ääniaineistojen luokittelu tai varustaminen tunnisteilla	Musiikkikappaleiden luokittelu tai varustaminen tunnisteilla
	Muunlaisten tietojen ryhmittely	Kohteiden (esim. asiakkaiden, tuoteominaisuuksien) ryhmittely ja segmentointi
	Yhteyksien havaitseminen	Sellaisten ihmisten tunnistaminen, jotka katsovat tiettyjä TV-sarjoja ja myös lukevat tiettyjä kirjoja
Ennustaminen	Tulosten todennäköisyyksien ennustaminen	Ennuste sille, että asiakas valitsee toisen toimittajan
	Ennusteet	Tuotteen kysynnän ennustaminen aiemman tietoaineiston pohjalta
	Arvofunktion määrittäminen	Palkkioiden ennakointi/arviointi dynaamisten pelien tulevien tilojen toimenpiteistä, kun aineistona on tuhannet aikaisemmin pelatut pelit
Tuottaminen	Visuaalisten kohteiden tuottaminen	Samantyyllisen maalauksen tuottaminen tietyn taiteilijan töiden pohjalta
	Kirjoituksen ja tekstin tuottaminen	Puuttuvien osien täydentäminen sivulle aiempiin teksteihin perustuvan koulutusaineiston pohjalta
	Ääniaineiston tuottaminen	Saman tyylin tai tyyllilajin musiikkikappaleen tuottaminen
	Muun tiedon tuottaminen	Puuttuvien datapisteiden lisääminen heikkolaatuisten säätietojen maiden dataan toisten maiden säätietoihin perustuvan koulutusaineiston pohjalta

Esimerkiksi luokitteluongelmissa kohteet (esim. valokuvat, videot, tekstit, äänet) on tunnistettava ja sitten liitettävä toisiinsa tai muihin tietolähteisiin. Yksi sovel-lusesimerkki on asiakkaiden ryhmittely erilaisiin luokkiin. Kohteiden ja tietojen välisten suhteiden luominen on myös edellytys ennusteille ja tekstien ja kuvien tuottamiselle, esim. videosta puuttuvan yksittäisen kuvan lisäämiselle. ■

2.3 SYVÄOPPIMINEN NEUROVERKOISSA

Hyvin pitkään sellaisetkin tehtävät, joihin pikkulapsikin pystyy – kuten kuvan esittämän kohteen tunnistaminen tai puheentun-nistus – olivat koneille ylipääsemätön kompastuskivi.

Tässä on viime vuosina tapahtunut muutos syväoppimisen ansiosta. Syväoppiminen perus-tuu neuroverkkoteknologiaan. Tässä yhteydessä ”syvällä” viitataan verkossa piilossa olevien kerrosten määrään – monimutkaisimmissa tällä hetkellä käytetyissä hahmontunnistusmenetel-missä, jotka perustuvat residuaaliseen syväoppimiseen, neuroverkon kerrosten määrä voi olla tuhat tai enemmänkin. ■

2.3.1 NEUROVERKOT JA SYVÄOPPIMINEN: PERUSPERIAATTEET

Neuroverkot perustuvat ihmisaivojen malliin, ja ne on suunniteltu ongelmanratkaisuun ihmistä jäljittelevällä tavalla. Ne ovat tiivisti toisiinsa liitettyjen ”solmuiksi” kutsuttujen prosessointielementtien, neuronien, verkkoja. Solmut vastaanottavat tietoa joko ympäristöstä tai toisilta neuroneilta, käsittelevät sen ja välittävät sen toisille solmuille tai ympäristöön.


Ainoastaan ulkokerrokset, eli syötekerros ja ulostulokerros näkyvät tarkkailijalle. Kaikki verkon sisällä tapahtuva jää näkymättömiin, minkä vuoksi validoinnissa ja varmuudessa tarvittavien luotettavuusarviointien teko on usein vaikeaa.

Keinotekoiset neuronit mallinnetaan ja järjestetään useiksi kerroksiksi peräkkäin tai päällekkäin. Jokainen verkon kerros antaa oman panoksensa (toivottavasti) oikean tuloksen tuottamiseen. Piirteiden erottaminen tapahtuu eri tasoilla toisistaan riippumatta. Yhden tason tulos toimii aina syöteenä seuraavalle tasolle. Kun verkkoon syötetään suuria määriä laadukasta opetusaineistoa, verkko oppii suorittamaan erilaisia tehtäviä.

Neuroverkot koostuvat kolmesta peruskerroksesta:

- syötekerros
- piilokerros (joita on yksi tai useampia)
- ulostulokerros.

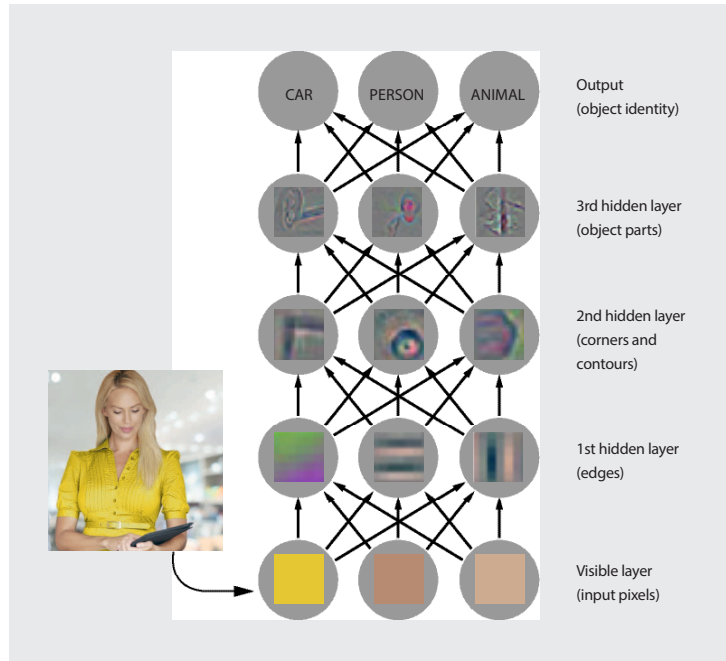
Esimerkki: Tietokoneen on verraten vaikeaa oivaltaa valokuvan merkityksellisyys ensi vilkaisulla, kuten ihminen oivaltaa. Merkityksellisen muodon erottaminen kuvapisteryhmästä on erittäin monimutkainen tehtävä, jonka suorittaminen suoraan on likipitään mahdotonta.



Syväoppimisessa neuroverkko purkaa kuvan moniin osakuviin, ja verkon yksi kerros käsittelee aina yhden osakuvan, esimerkiksi alueiden reunat, kulmat, ääriviivat jne. Ensimmäinen piilokerros voi esimerkiksi tunnistaa alueiden reunat vertaamalla vierekkäisten kuvapisteen kirkkautta ja välittää tämän tiedon toiselle piilokerrokselle, joka puolestaan etsii kulmia tai ääriviivoja (nämähän eivät itse asiassa ole muuta kuin reunoista koostuvia ryhmiä). Tämän tiedon pohjalta kolmas piilokerros hakee sitten sellaisia kulmien ja reunojen ryhmiä, jotka ovat tietyille kohteelle tyypillisiä. Tämä prosessi jatkuu, kunnes kohde on tunnistettu. ▶

Jokaiselle solmujen väliselle yhteydelle annetaan painoarvo, jota muutetaan oppimisprosessin aikana. Positiivinen painoarvo tarkoittaa, että neuronin kytkentä toiseen neuroniin on vahvistava, ja negatiivinen taas, että kytkentä on vaimentava. Jos painoarvo on nolla, neuroni ei vaikuta toiseen neuroniin millään tavoin. Samoin kuin arkielämässä meiltä voi jäädä huomaamatta hytysenpisto tai punkin purema, neuroverkot vaativat "aktivointifunktion", joka karsii pois pienimmät arvot ja keskittyy niihin keskinäisiin suhteisiin, jotka ovat aidosti merkityksellisiä.

Yllä olevassa esimerkissä kuvan oikealla puolella oleva "kuvapistearvo" (syötearvo) vastaa luokkaa "ihminen" (tulosarvo). Jos neuroverkon tuottama tulosarvo ei vastaa luokitusta, virheilmoituksen sisältävä signaali lähetetään takaisin verkkoon. Tämän seurauksena painoarvoja muutetaan, ja tunnistusta yritetään uudestaan. Ajan mittaan nämä painoarvojen pienet muutokset kumuloituvat siten, että verkko oppii yhdistämään sille annetun kuvapistearvon oikeaan luokkaan. ■



2.4 KOGNITIIVINEN TIETOJENKÄSITTELY

Jotkut tutkijat puhuvat vielä yhdestä muusta tekoälyn tyypistä, kognitiivisesta tietojenkäsittelystä.

Sillä tarkoitetaan järjestelmiä, jotka suorittavat tiettyjä tehtäviä tai tekevät tiettyjä päätöksiä joko ihmisten apuna tai heidän sijastaan. Tällaisia järjestelmiä käytetään esimerkiksi korvauskäsittelyssä vakuutusyhtiöissä tai diagnostiikassa sairaaloissa.

Nämä järjestelmät kykenevät käsittelemään moniselitteisyyksiä ja epämääräisyyksiä, ja ne pystyvät varsin itsenäiseen toimintaan omalla tietämysalueellaan. ■



TEKOÄLY LOGISTIKASSA


Crisp Research AG:n vuonna 2016 IT-päätäjien keskuudessa tekemässä tutkimuksessa havaittiin logistiikan olevan yksi niistä sektoreista, joilla erittäin monet yritykset hyödynsivät jo aktiivisesti koneoppimisen prosesseja.

Current status of industries in the implementation of machine learning (n=168)

Sector	In evaluation/ planning	Initial experiences & prototypes	Being used in selected sectors	In productive operation in broad sections of the company
Automobile and automotive supplier	60 %	20 %	0 %	20 %
Machine and system engineering	52,9 %	17,7 %	29,4 %	0 %
Chemical industry	30 %	40 %	30 %	0 %
Metalworking industry	38,5 %	46,2 %	15,4 %	0 %
Consumer goods and trade	18,8 %	43,8 %	25 %	12,5 %
Logistics and transportation	16,7 %	41,7 %	41,7 %	0 %
Bank and insurance	28,6 %	33,3 %	28,6 %	9,5 %
Professional services	38,5 %	23,1 %	30,8 %	7,7 %
Pharmaceuticals and healthcare	22,2 %	55,6 %	22,2 %	0 %
IT, telecommunications, and media	11,8 %	47,1 %	26,5 %	14,7 %
Public sector and education	27,8 %	44,4 %	27,8 %	0 %



Tämä johtuu ehkä osittain siitä, että taustalla olevien olosuhteiden muutos kävi ilmeiseksi muita sektoreita varhaisemmassa vaiheessa ankarasti kilpailulla logistiikkasektorilla. Tähän oli syynä vaatimusten muuttuminen (esim. verkkokauppa) yhdessä nopean digitalisaation kanssa, sekä digitalisaatioon nojaavien uusien liiketoimintamallien nousu. Logistiikkasektori on vuosien mittaan joutunut kamppailemaan jatkuvasti tiukkenevien kilpailukykyvaatimusten kanssa ja tottunut samalla kohtaamaan lukuisia uusia haasteita. Nämä haasteet kasvavat entisestään, kun verkkokauppatoimijat nokittelevat yhä suuremmilla lupauksilla, joiden seurauksena kuluttajien odotukset kasvavat. Tällaisia uusia vaatimuksia ovat mm. toimitus samana päivänä sekä tuotteiden jatkuva ja välitön saatavuus, jota toivotaan myös kivijalkakaupassa. Tämän lisäksi pienten toimitusmäärien usein toistuvat tilaukset ovat kasvussa.



Nämä kehityskulut vaativat logistiikkayrityksiä järjestelemään uudella tavalla nykyiset liiketoimintamallinsa ja strategiansa. Yksi ratkaisu on kaikkien logistiikkaprosessien laajamittainen automatisointi ja niiden integrointi hallittaviksi standardoidulla IT-järjestelmällä. Tällainen järjestelmä perustuu silti edelleen ihmiskäyttäjien syötteeseen, vaikka yksittäiset prosessivaiheet toimivatkin paljolti itseohjautuvasti integroitujen anturien yms. ansiosta.

Tässä kohtaan kuvaan astuu ilmiö, jotka kutsutaan "dimensiokiroukseksi": kun logististen operaatioiden koko ja kompleksisuus kasvavat – tai kun tarvitaan aikakriittisiä päätöksiä – jopa aikaisemmin toimineet, vakiintuneet matemaattiset optimointialgoritmit epäonnistuvat tehtävässään. Aikaikkuna, jossa päätös on tehtävä, lyhenee jatkuvasti samaan aikaan, kun ongelman koko kasvaa.

Tekoälyteknologioiden avulla logistiikkapalvelujen tarjoajat pystyvät paitsi erottautumaan kilpailijoistaan, myös kasvattamaan voittojaan. Toimitusketjun kaikissa eri vaiheissa kertyvien suurten datamäärien älykäs analysointi mahdollistaa aikaisemmin piiloon jääneiden keskinäisten suhteiden havaitsemisen. Tämän tiedon pohjalta voidaan kehittää realistisia lähitulevaisuuden skenaarioita ja suunnitella yleiset tavaravirrat ketterämmiksi ja vähemmän häiriöalttiiksi.

Jo nykyisin tekoälyteknologioita käytetään monissa sovelluksissa. Nämä ovat vielä toistaiseksi usein erillisiä ratkaisuja, mutta suuntaus on selvästi kohti integraatiota.

Accenture Strategy yhtiön Manish Chandra ja Anand Darbhe uskovat jopa, että "tekoälyn käyttö toimitusketjussa johtaa lopulta ekosysteemiin, jossa eri arvoketjut linkittyvät toisiinsa ja mahdollistavat tuotteiden ja tiedon saumattoman virtauksen alusta loppuun asti".

Seuraavassa esitellään eräitä logistiikan alueita, joilla tekoälyä tällä hetkellä hyödynnetään. Esimerkit eivät pyri olemaan kattava kokonaiskuva, vaan niiden ensisijainen tarkoitus on korostaa tekoälyteknologioiden tarjoamia mahdollisuuksia. ■

3.1 SIMULOINTI

Logistiikkajärjestelmien ja prosessien suunnittelussa simulaatiot ovat olleet keskeisessä roolissa jo monta vuotta.

Simulaatiomalleilla voidaan määrittellä tulokset arvioimalla järjestelmän dynaaminen käyttäytyminen asetetuilla parametreilla. Logistiikkajärjestelmän läpimenomäärien ja parametrien väliset riippuvuudet eivät useinkaan ole aivan ilmeisiä, minkä vuoksi manuaalinen optimointi on vaikeaa. Optimointi saattaa myös olla mahdollista ainoastaan tietyille käyttötapaukselle ilman yleisempää sovellettavuutta.

”Digitaalisen kopioon” (digital twin) perustuva simulaatio on vienyt tämän alan kehitystä viime aikoina voimakkaasti eteenpäin. Kun tietystä mallista tehdään lähes identtinen digitaalinen malli, jolle annetaan syötteenä riittävän laaja tietoaaineisto, tekoälyalgoritmit pystyvät oppimaan ja jatkamaan oppimista sekä päivittämään oppimansa logistisen ympäristön muuttuessa.

Mahdollisuus opettaa tekoälyä virtuaalimallien avulla yhdistää olemassa olevan, kypsän ja käytännössä koetellun teknologian laskennallisen tieteen tarjoamiin uusiin mahdollisuuksiin. Tärkeää on vain mallien riittävän hyvä laatu. Tehtävästä riippuen tässä voidaan käyttää erilaisia ongelmanratkaisumenetelmiä (FEM/CFD, systeemidynamiikka, tapahtuma- tai agenttipohjainen mallinnus jne.). ■

Sisälogistiikkajärjestelmien valmistajien tapauksessa tekoäly voi hyödyntää monista sellaisista aikaisemmista tehtävistä kertynyttä dataa, joiden parametrit muistuttavat käsillä olevan ongelman parametreja. Tässäkin algoritmien menestyksellisen oppimisen kannalta on tärkeää, että käytössä on riittävän laaja ja edustava tietoaaineisto, joka ei aiheuta ylisovittamisen riskiä.

3.2 OPTIMOINTI

Toinen alue, jolla tekoäly on jo käytössä, on logistiikkaprosessien optimointi siten, että ne pystyvät sopeutumaan itsenäisesti ja dynaamisesti markkinoiden muuttuviin vaatimuksiin.

Tämä voi tarkoittaa esimerkiksi tilauskäsittelyn sovittamista kausivaihteluihin tai sellaisten tilauskäyttäytymisen toistuvien mallien havaitsemiseen, joita ihminen ei suoralta kädeltä näe. ”Perinteinen” optimointi alkaa aina valmiiksi määritellystä, muuttumattomasta tavoitteesta (kohdefunktio). Nykyaikaisessa logistiikassa tämä rajoitus on ongelmallinen, koska optimaalinen toiminta vaihtelee asiakkaan liiketoinnasta riippuen. ■

3.2.1 HITACHI JA H: TEKOÄLY ANTAA OHJEITA VARASTOTYÖNTEKIJÖILLE

Japanilainen elektroniikkakonserni Hitachi on kehittänyt H-nimisen tekoälyteknologian, jota se on sovittanut erilaisiin käyttötarkoituksiin. H on tekoälyyn pohjautuva versio Kaizen-menetelmästä, joka perustuu työprosessien jatkuvaan kehittämiseen.

Tekoälyjärjestelmä analysoi, kuinka työntekijät toimivat ongelmatilanteissa. Siitä huolimatta, että työntekijät usein toimivat selvien ohjeiden tiukoissa puitteissa, he kuitenkin etsivät jatkuvasti tapoja parantaa omaa työnkulkuaan, vaikka parannukset olisivatkin hyvin pieniä. H kerää tietoa tästä ja arvioi yksittäisten lähestymistapojen tehokkuuden. Jos se havaitsee jonkin lähestymistavan auttavan tehokkuuden parantamisessa, toimintatapa analysoidaan syvällisemmin ja välitetään sitten työntekijöille työohjeen muodossa.

Samaan aikaan H pystyy reagoimaan lyhytaikaisiin muutoksiin ja antamaan ohjeita eritystilanteissa. Tekoäly pystyy myös ottamaan analyyseissään huomioon säätiedot ja kysynnän vaihtelut. Esimerkiksi huonon sään jaksolla rahtikuljetusten saapumiset ja lähdöt saattavat viivästyä ja samaan aikaan sadevaatteiden kysyntä kasvaa.

H toimii ilman etukäteisohjeistusta valvovalta ihmiseltä. Tekoälyjärjestelmä antaa ohjeet suoraan työntekijöille tai siihen liitettyihin järjestelmiin. Tämä mahdollistaa nopeat vasteajat ja toimenpiteet, joilla tehokkuuden parannukset voidaan toteuttaa viipymättä. Hitachi kertoo kasvattaneensa tuottavuutta H:n avulla 8 prosenttia suhteessa vastaaviin, ilman tekoälyä toimiviin varastoihin. ■




3.2.2 ZALANDO: REITTIEN OPTIMOINTIA SYVÄOPPIMISEN AVULLA

Varastokeräilyn keskeinen ongelma on varastotyöntekijöiden optimaalisten reittien laskenta. Zalandoossa neuroverkko on koulutettu varmistamaan mahdollisimman lyhyet keräilyreitit. Tekoälyalgoritmi tuottaa ratkaisun, joka mahdollistaa keräilytyön kohdentamisen eri työntekijöille tehokkaammin, mikä nopeuttaa keräilyprosessia.

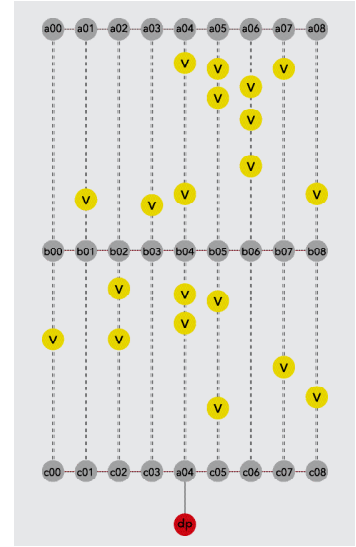
Lähtöoletuksena oli yksinkertaistettu varasto, jossa kerättävät nimikkeet sijaitsevat samansuuntaisissa hyllystöriveissä. Hyllystöjen välissä kulkee käytävät pitkittäin ja poikittain. Varastotyöntekijä vastaanottaa keräilylistan ja kulkee karusellivaunujen kanssa käytäviä pitkin poimien vaaditut nimikkeet hyllyistä. Keräilylistan ja reitin yhdistelmä on periaatteessa monimutkaisempi versio kuuluisasta kauppamatkustajan ongelmasta.

Zalandon IT-asiantuntijat ovat kehittäneet optimaalisen kärrykeräilyn algoritmin (Optimal Cart Pick, OCaPi), joka ei arvioi ainoastaan työntekijöiden reittejä, vaan myös karusellivaunujen kulkureittejä, sillä nämä vaunut jätetään toisinaan poikittaiskäytävälle siksi aikaa, kun työntekijä käy keräämässä tavaraa hyllystöistä. Näistä tiedoista se laskee lyhimmän reitin. ▶



Ikävä kyllä, OCaPi-algoritmilta kestää useita sekunteja laskentaan, jolla laaditaan optimaalinen keräilylista. Zalandoon saapuu joka tunti tuhansia tilauksia, joten tämä aika on liian pitkä, jotta algoritmia voisi hyödyntää käytännössä. Aika haluttiin siksi lyhentää muutamaksi millisekunniksi. Tätä tarkoitusta varten laadittiin miljoona satunnaista keräilylistaa, joista kuhunkin liitettiin OCaPi-algoritmin sille laskema keräilyaika. Sen jälkeen nämä tiedot syötettiin neuroverkkoon. Tällä tavoin kehitettiin neuroverkkoarkkitehtuuri, joka pystyy laskemaan reittiajat, joissa laskentavirhe on vain hieman yli 32 sekuntia tunnissa. Tämä on käytännössä lähes merkityksetön luku.

Tekoälyjärjestelmän testaamista varten laadittiin optimointialgoritmi, joka aloittaa 40 tilauksella, joissa kussakin on 2 nimikettä. Tilaukset jaettiin satunnaisesti kahteen keräilylistaan. Kun tilauksia on 40, on olemassa noin 69 miljardia eri tapaa jakaa tilaukset kahteen keräilylistaan. Tekoälyn laskemat reitit vähensivät matka-aikaa 11 prosenttia yksittäistä keräilyä tuotetta kohden. ■



3.2.3 TEKOÄLY JA ITSEOHJAUTUVAT

Nykyisin on käytössä varastoja, joiden toimintaperiaatteita ihmistarkkailija ei pysty ymmärtämään, sillä niitä hallinnoi tekoäly. Kaikille niille on yhteistä robottien – ja erityisesti itseohjautuvien kuljetusvaunujen (AGV) – käyttö. Näissä varastoissa tuotteita ei enää ryhmitellä tuoteryhmittäin ja sijoitella toistensa kanssa vierekkäin, kuten olemme tottuneet näkemään esimerkiksi valintamyymälöissä. Tuotteet sen sijaan sullotaan eri hyllystöihin ja käytäviin tavalla, joka vaikuttaa täysin kaoottiselta. Tällainen järjestely aiheuttaisi tarpeetonta kulkua ja tarpeettoman pitkiä etsintäaikoja ihmiskeräilijälle, mutta itsenäisille roboteille se ei ole ongelma. Kun tilaus saapuu, ensimmäinen vapaa robotti poimii omaa sijaintiaan lähinnä olevan tuotteen ja vie sen ihmispakkaajille varaston pätyyn.

Itse robotit eivät ole erityisen ”älykkäitä”, mutta järjestelmää pyörittävä tekoälyjärjestelmä sitä vastoin on. Se käsittelee varastoa jatkuvasti muuttuvina määrinä ja parametreina; tämä pätee yhtä lailla kunkin tuotteen kysyntään kuin jokaisen robotin kunkin hetkeen sijaintiin. Jos käytetään Kiva Systems yhtiön robotteja, myös varaston pohjapiirros muuttuu jatkuvasti, sillä nämä robotit eivät kuljeta pakkaajille yksittäisiä tuotteita, vaan kokonaisia hyllystöjä.

Toinen lähestymistapa on älykkäiden itseohjautuvien vaunujen käyttö. AGV-vaunut

pystyvät havainnoimaan ympäristöään toisistaan riippumatta laserskannerien, anturien ja RFID-sirujen avulla ja navigoivat kukin itsenäisesti reittinsä päämäärään. AGV-vaunut muodostavat yhdessä ”parven”. Keskitettyä ohjausjärjestelmää ei tarvita, vaan AGV-vaunut hoitavat itse sisääntulevien kuljetustilausten jakamisen, päättävät säännöt oikean reitin löytämiseksi ja jakavat tiedon omasta sijainnistaan toisille vaunuille. Koska kukin AGV-vaunu käsittelee tiedot hajautetusti, ohjaus jakautuu käytännössä useille vaunuille. Mikäli eteen tulee esteitä tai toimintahäiriö, WWparvi reagoi riippumattomasti ja ratkaisee ongelman. ■



AI-controlled KIVA robots in action

3.3 ENNAKOIVA ANALYTIikka

Big data teknologiat ovat nykyisin osa ketterää toimitusketjua. Ainoastaan näitä teknologioita käyttämällä on mahdollista käsitellä ne valtavat datamäärät, joita mm. anturit tuottavat, ja mallintaa ympäröivä reaali maailma oikeiden päätösten tekoa varten. Big data teknologiat mahdollistavat ennusteet ja kehittyneet skenaarioanalyysit ja sallivat siten tarkan kapasiteetin suunnittelun sekä toimitusketjujen ja varastojen optimoinnin.

Ennakoiva analytiikka perustuu ensisijaisesti tiedonlouhintaan, joka on perinteinen tekoälyn käyttöalue. Se tarkoittaa toistuvien mallien etsimistä suurista datamääristä. Tehtävässä tarvitaan tilastolaskentaa, mahdollisesti peliteorian elementtejä, semanttisia prosesseja ja operaatiotutkimuksen menetelmiä.


Ennakoivan analytiikan ensimmäinen vaihe on kuvaileva analytiikka, jota seuraa toinen vaihe, jota kutsutaan ohjailevaksi analytiikaksi. Tässä toisessa vaiheessa tekoäly antaa toimintasuosituksia havaittujen keskinäisten riippuvuuksien pohjalta.

Miekkäiden tulosten edellytys on datan luotettavuus. Ennuste voi olla ainoastaan niin hyvä, kuin järjestelmälle syötetty tietoaaineisto. Datan luotettavuus ei ole välttämättä itsestäänselvyys. Liiankin usein tiedot syötetään yhä manuaalisesti, ja siten aineiston joukkoon eksyy tahattomia virheitä. Erityisesti logistiikassa on kuitenkin siitä mainio tilanne, että jatkuvasti syntyvä data tarjoaa loistavan pohjan järjestelmän toistuvaan mukauttamiseen ympäristön ja olosuhteiden muuttuessa.

Vaikka tekoälyjärjestelmät kykenevätkin melko hyvin toipumaan yksittäisistä virheistä suurissa datamäärissä, pienten poikkeamien kasaantuessa on aina riski siitä, että järjestelmästä saadaan virheellisiä tuloksia. Kysymys ei ole siten vain datan keräämisestä, vaan sen ”ymmärtämisestä” alusta alkaen.

Yksi tavallinen esimerkki on eri mittayksiköiden käyttö. Jos joissakin tietueissa käytetään yksikkönä ”metrejä”, ja toisissa taas ”jalkoja”, on varmistettava huolellisesti, että kaikki tiedot muunnetaan ensin etukäteen määriteltyyn mittaussyksikköön. Tällaisista asioista huolehtimiseen tarvitaan asianmukaisesti koulutettuja ja kokeneita datatieteilijöitä. Tämä on verraten uusi ammattinimike asiantuntijoille, jotka pystyvät käsittelemään valtavia datamääriä ja johtamaan niistä mahdollisimman suuren hyödyn ajantasaisten tietojenkäsittelytaitojensa, matemaattisten ja tilastollisten prosessien hyvän tuntemuksensa sekä toimeksisaajan teknisen ympäristön täsmällisten tietojen avulla.

Vuonna 1986 tapahtunut Challenger-avaruussukulan katastrofi on hyvä esimerkki siitä, mitä voi tapahtua, jos ongelmaa ei analysoida ja oteta huomioon kaikessa monimutkaisuudessaan. Räjähdyksen käynnistäneen rengastiivisteiden kestävyysmittausten pelkkien vikaantumistulosten tarkastelu ei yksinään tarjonnut riittäviä tietoja, joiden perustella olisi voinut arvioida riskin, joka liittyy sukulan laukaisemiseen pakkasyön jälkeen. Jos epäonnistuneiden testien tuloksia olisi tarkasteltu onnistuneiden testien tulosten kanssa, vikaantumisten kerääntyminen mataliin lämpötiloihin ja moitteettomien tulosten kerääntyminen korkeampiin lämpötiloihin olisi välittömästi saanut tutkijat havaitsemaan, että lämpötila oli tiivisteiden kestävyyskannalta kriittinen tekijä. ■



3.3.1 OTTO: PALAUTUKSET VÄHENIVÄT KAHDELLA MILJOONALLA TEKOÄLYN AVULLA

Otto on monikanavainen yritys ja yksi Saksan suurimmista tekstiili- ja muotialan vähittäiskauppiasta. Konsernin kokonaisliikevaihdosta 75 % syntyy verkkokaupasta. Konserni myy 1,8 miljoonaa tuotenimikettä 3 600 eri tuotemerkiltä.


Kuten muillakin verkkokaupparyityksillä, tuotepalautukset aiheuttavat Otolle merkittäviä kustannuksia – useita miljoonia euroja vuodessa. Saatavilla olevan datan analysointi paljasti, että asiakkaat, jotka saivat tilaamansa tuotteet kahden päivän kuluessa tilauksesta, palauttivat niitä keskimääräistä vähemmän. Lisäksi asiakkaat olivat tyytyväisempiä, jos tilatut tuotteet tulivat yhdessä lähetyksessä sen sijaan, että ne jakautuisivat useampiin toimituksiin.

Koska Otto myy muiden valmistajien tuotteita, eikä pidä niitä varastossa suuria määriä, tilanne oli vaikea. Oli joko odotettava, että kaikki tilauksen tuotteet saapuivat, jotta ne voitiin lähettää yhtenä toimituksena, mikä yleisesti ottaen vei pidempään kuin kaksi päivää. Toinen vaihtoehto oli toimittaa tuotteet heti, kun ne olivat saatavilla, mutta silloin tilaukset jakautuivat useisiin toimituksiin.

Otto otti käyttöön syväoppimisalgoritmin, joka kehitettiin alun perin hiukkasfysiikan sovelluksia varten. Tekoäly analysoi noin kolme miljardia tietuetta ja 200 muuttujaa, mukaan lukien maksutapahtumat, Otto-sivuston haut ja sääennusteet laatiakseen ennusteen seuraavan viikon ostoksista.

Tekoälyjärjestelmä osoittautui tässä ilmeisen hyväksi. Se kykenee ennakoimaan 90 prosentin tarkkuudella seuraavien 30 päivän aikana myytävät tuotteet. Tämän ansiosta Otto pystyy nyt tilaamaan 200 000 tuotetta etukäteen joka kuukausi ja lähettämään ne nopeammin yhtenä toimituksena, kun asiakas tekee tilauksen. Lopputuloksena tekoälyjärjestelmän käyttöönoton jälkeen tuotepalautusten vuosittainen määrä on laskenut noin 2 miljoonalla tuotteella. Vähäisempi uloslähtevien pakettien määrä tarkoittaa, että myös hiilipäästöt ovat vähentyneet merkittävästi.

Zalandolla on puolestaan kokeilussa toisenlainen lähestymistapa. Tuotepalautusten vähentämiseksi tehdään kokeita, jotka liittyvät asusteiden koko-ongelmaan. On nimittäin havaittu, että 30–40 prosenttiin palautuksista syynä on väärä koko. Tavoitteena on vähentää tätä määrää. Tavoitteen saavuttamiseksi Zalando hyödyntää koneoppimista. Ensimmäisenä on paneuduttu kenkiin. Mies- ja naispuoliset kokeilijat sovittavat oman kokonsa kenkiä, ja raportoivat siitä, ovatko ne sopivan kokoisia. Tekoäly arvioi nämä tiedot, ja yrittää löytää niistä järjestelmällisyyksiä. Tulevaisuudessa, kun yleensä kokoa 39 käyttävä asiakas on tilaamassa tiettyä kenkää, järjestelmä pystyy sanomaan hänelle, että tässä kyseisessä merkissä koon 40 kenkä saattaisi sopia paremmin. ■



3.3.2 ZALANDO: OMA KAUPPA JOKAISELLE ASIAKKAALLE

Zalando aloitti kenkien ja vaatteiden vähittäiskauppiaina, mutta näkee itsensä nykyisin teknologiakonsernina, jonka tavoitteena on tulla koko muotialan palveluntarjoajaksi. Tämän vuoksi konsernissa työskentelee nykyään useita tuhansia ohjelmoijia. Handelsblatt-lehden raportin mukaan konserni aikoo investoida kymmeniä miljoonia euroja älykkäisiin algoritmeihin seuraavien 18 kuukauden aikana. Näillä algoritmeilla ei toteuta vain nykyisenkaltaisia suositustoimintoja, vaan luodaan kullekin asiakkaalle yksilöllinen oma verkkokauppa, joka tarjoaa optimoidun, tiivistetyn valikoiman niiden 300 000 tuotteen joukosta, jotka Zalando joka sesongilla markkinoille tuo. ■



3.3.3 TEKOÄLYÄ ILMASSA

Varastoon tavaraluetteloon vahingossa syötetyt virheelliset luvut ja tiedot ovat yleinen murheenkryyni suurissa varastoissa. Pelkästään Yhdysvalloissa tällaiset virheet aiheuttavat miljardien dollarien arvosta tappioita. Tekoäly voi auttaa myös tämän ongelman ratkaisussa.

Yhdysvaltalainen Intelligent Flying Machines yhtiö (IFM) on kehittänyt droonin, joka ei tarvitse GPS-tekniologiaa tilassa suunnistamiseen, vaan pystyy tekoälyalgoritmien avulla toimimaan erittäin tarkasti suljetussa tilassa. Kamera tallentaa tuotteet ja niiden sijainnit, minkä jälkeen tietoja verrataan varastohallintajärjestelmän (WMS) tietoihin. Älykkäät algoritmit ovat tämän ratkaisun perusta. ■

3.4 ENNUSTAVASTA KUNNOSSAPIDOSTA ENNAKOIVAAN KUNNOSSAPITOON

Alan toimijat pyrkivät saavuttamaan entistä paremmin (miltei) täysin luotettavan laitteistokokoonpanon varaston maksimaalisen suorituskyvyn takaamiseksi ja tuotantoseisokkien ehkäisemiseksi. Tekoälyteknologioita käytetään myös ennustamaan koneiden ja järjestelmien (jäljellä olevaa) käyttöikä. Ennustavaa kunnossapitoa käytetään havaitsemaan laitteistokokoonpanon osien lähestyvät vikatilanteet ja käynnistämään ennakoivat huoltotoimenpiteet vikaantumisen estämiseksi jo etukäteen. Ennustava kunnossapito lepää neljän pilarin varassa:


- Tiedon kerääminen
- Tiedon siirto
- Tiedon arviointi, ja
- Toimenpiteet, jolla varmistetaan järjestelmän toiminnan jatkuvuus.

Kustannussyistä useimmissa teollisissa kokoonpanoissa tiedon kerääminen tapahtuu edelleenkin testien ja huoltotöiden yhteydessä. Anturien ja tiedonsiirtolaitteiden hintojen laskemisen ansiosta ollaan siirtymässä reaaliaikaiseen digitaaliseen valvontaan. Kerätyt tiedot kootaan keskitetyksi, ja niitä voidaan arvioida erilaisista näkökulmista. Jos ongelmien syntyminen todennäköisyyden havaitaan nousseen, voidaan aloittaa tarvittavat toimenpiteet hyvissä ajoin ja estää näin järjestelmän vikaantuminen tai järjestelmän pitkä seisokkiaika.

Sopivasti opetetut tekoälyjärjestelmät pystyvät jo nyt tarjoamaan apua tällaisissa tehtävissä, varsinkin mitä tulee valtavan datavirran analysointiin. Jotta ennustava kunnossapito onnistuu asianmukaisesti, kaikkien seurattavien komponenttien liikkeet on kerättävä ja tallennettava niihin liittyvien parametrien kanssa. Toimintavarmuuteen vaikuttavat tekijät vaihtelevat sen mukaan, millainen laite on kyseessä. Esimerkiksi kuormauslaiturin tapauksessa näitä tekijöitä ovat mm. avaus- ja sulkemistoiminnot, kaikki niihin liittyvien komponenttien toiminnot ohjausjärjestelmästä pneumaattisten sylinterien ja rullien kulumiseen.

Tämän pohjalta voidaan siirtyä ennakoivaan kunnossapitoon. Tulossa olevan vikatilanteen ennusteen perusteella varataan valmiiksi huoltoajankohta, tarvittavat huoltoasentajat, tilataan tarvittavat varaosat, ja huolto suoritetaan ruuhkahuippujen ulkopuolella. Suunnitelmassa voidaan toimia tätäkin hienostuneemmin ja säätää kyseisen laitteen parametreja siten, että vauriolle altistavia liikkeitä ei enää suoriteta täydellä teholla, vaan niin varovaisesti kuin on mahdollista infrastruktuurin optimaalisen toiminnan kannalta. Näin voidaan vähentää riskiä, että vika ilmaantuisi ennen suunniteltua huoltoajankohtaa.

Olisi myös virhe olettaa, että tässä voitaisiin luottaa pelkästään antureihin. Nykyaikaiset anturit ja niiden yhteen liittämisen menetelmät mahdollistavat virheellisten anturiarvojen havaitsemisen, ja tekoäly pystyy arvioimaan nämä havainnot yhdessä toisten mittaustulosten kanssa. Ongelma ei aina välttämättä ole itse laitteistossa – anturi voi vikaantua, eikä tämän tarvitse johtaa järjestelmän huoltokatkoon. ■



YHTEENVETO: KUINKA TEKOÄLY MUUTTAA ARVOKETJUA

Jo nyt voidaan varmuudella sanoa, että tekoälyn käyttö tulee lähivuosi-
na vaikuttamaan valtavasti logistiikkaprosesseihin kaikilla tasoilla. Edellä
esitetyt esimerkit näyttävät, missä laajuudessa tekoäly on jo tällä hetkellä
käytössä logistiikkasektorilla.

Monet asiantuntijat uskovat, että tekoälyteknologiat tulevat vaikuttamaan erityisesti seuraaviin
osa-alueisiin:

- Tuottavuus: Tekoäly kasvattaa merkittävästi tuottavuutta erityisesti verkkokaupan toimijoiden varastoissa, koska se pystyy laskemaan automaattisesti parempia ratkaisuja.
- Viestintä: Varastotyöntekijät ja esimiehet joutuvat kommunikoimaan toistensa kanssa ilman viivettä, jotta muutoksiin tai häiriöihin pystytään vastaamaan. Tekoälyn ohjaamat, verkoksi yhdistetyt robotit varmistavat lähes samanaikaisen ja virheettömän viestinnän, mikä myös parantaa tuottavuutta.
- Varastonhallinta: Jo aivan lähivuosina, suuret osat varastoja tulevat olemaan täysin automatisoituja. Tekoälyteknologiat ovat muuttumassa yhä useammin järjestelmään kiinteästi kuuluviksi komponenteiksi, etenkin mitä tulee lyhyen ja keskipitkän aikavälin ennusteisiin.
- Henkilöstökulut: Tekoälyn ohjaama resurssisuunnittelu tehostaa henkilöstön käyttöä ja johtaa matalampiin henkilöstökuluihin tai parempaan toimintavarmuuteen, kun voidaan suunnitella reservit esimerkiksi sairastapauksia varten.
- Robotiikka: Tekoälyn ohjaamat robotit lyhentävät keräilyaikoja.
- Varastointimäärät: Tekoälyteknologiat johtavat pienempiin varastomääriin ja nopeampiin kiertoaikoihin.

Tämän lisäksi DHL:n Logistics Trend Radar tutkimuksen mukaan voidaan nähdä kaksi yleissuuntausta, jotka ainoastaan tekoäly on tehnyt mahdolliseksi:

- Ennakoiva logistiikka: Kysyntätrendien ennustaminen vaikuttaa koko toimitusketjuun alkaen valmistajista, jotka voivat kiihdyttää tuotantoa, kuljetusliikkeisiin, jotka voivat varata oikean määrän kuljetusajoneuvoja valmiiksi, vähittäiskauppiaisiin, jotka voivat tilata ja varastoida oikeita tuotteita ennakoivasti ja sovittaa henkilöstösuunnittelun vastaamaan ennakoitua kysyntää. Tämän lisäksi ennakoiva logistiikka mahdollistaa toimitusketjun riskien havaitsemisen jo varhaisvaiheessa, olipa sitten kyse ajoneuvon tai laitteen vikaantumisesta tai kausiluontoisista epidemioista, jotka vaikuttavat henkilöstön poissaoloihin.
- Itseoppivat järjestelmät: Koneoppimista käytetään käsinkirjoitettujen tekstien (esim. kirjeiden tai pakettien osoitemerkinnet) lukemiseen sekä varastossa tai keräilyn aikana toistuvien tapahtumien havaitsemiseen ja näiden havaintojen hyödyntämiseen keräilyssä. Nimikkeiden ripeät ja määrältään oikeat automaattiset lisätilaukset voidaan myös optimoida itseoppivien algoritmien avulla.



Monissa tapauksissa tässä mainitut esimerkit ovat kuitenkin edelleen erillisiä ratkaisuja, jotka synnyttävät myös huomattavia kustannuksia prosessointitehon ja ohjelmoinnin muodossa. Tarvitaan mittavia henkilöstö- ja teknologiainvestointeja. Tästä syystä oman tekoälyosaston perustaminen ei ole kustannustehokasta etenkin keskisuurille yrityksille. On olemassa kuitenkin kokeneita ulkopuolisia palveluntarjoajia, jotka voivat tarjota näitä palveluita.

Ei kannata koskaan unohtaa sitä, että integroidussa toimitusketjussa, varastointijärjestelmän on pystyttävä vastaamaan tekoälyn tuottamaan informaatioon, tai muuten meillä on taas uusi erillinen järjestelmä. Tekoälyteknologioiden asteittainen integrointi kattavaan ja skaalautuvaan logistiikkaohjelmistoon näyttäisi tällä hetkellä parhaalta strategialta. Tällä tavoin edeten häiriöt voidaan pääosin välttää ja järjestelmää voidaan laajentaa lisäelementeillä vaihe kerrallaan.

Tämä lähestymistapa myöskin varmistaa, että järjestelmän hallinta pysyy käsissä. Ennakoimattomia muutoksia varten kannattaa aina myös laatia varasuunnitelmat, joilla voidaan palata edeltävään tilanteeseen. Vain tällä tavoin voidaan taata varaston keskeytymättömän toiminta. ■



Kuvateksti: SSI SCHÄFERin WAMAS® Lighthouse -ohjelmisto on keskitetty informaatioalusta, joka analysoi ja visualisoi koko toimitusketjun. Useiden seurantanäyttöjen avulla sillä voi seurata logistiikkajärjestelmien ja prosessien kunkin hetkisiä suorituskykytietoja sekä laatia ja suorittaa integroituihin tekoälyalgoritmeihin perustuvia skenaarioita.

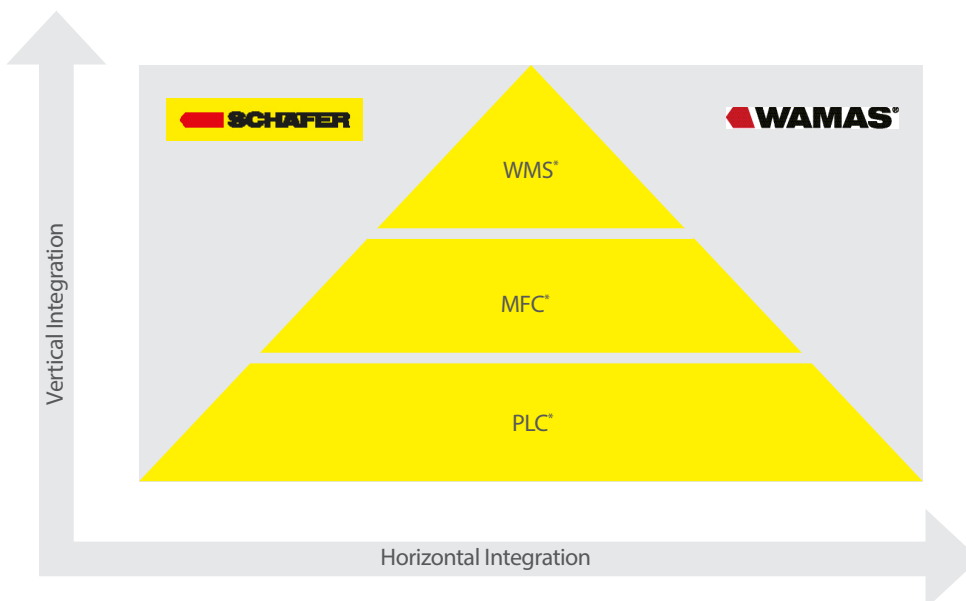


SSI SCHÄFERIN LÄHESTYMISTAPA

Integroitu lähestymistapa on välttämätön etenkin varastoteknologiassa. Vaikka Teollisuus 4.0:n kaltaisissa järjestelmissä hajautettu ohjaus on peruslähtökohtana, hajautetusti ohjattujen optimointiprosessien on myös muodostettava osa integroitua prosessia ja niiden on toimittava harmonisesti toistensa kanssa.

Kuinka tämä voi toimia, jos komponentit tai alijärjestelmät tulevat eri valmistajilta, toimittajilta tai kumppaneilta? Mitä rajoituksia automaattisesti syntyy, jos tarvittavaa takaisinkytkentää ei pystytä tarjoamaan rajapinta- tai toiminnallisten ongelmien vuoksi erityisesti silloin, kun menetelmät perustuvat ohjattuun oppimiseen tai vahvistusoppimiseen? Ja viimeisenä, mutta ei vähäisimpänä: kuinka tehokkaasti tekoälyä voidaan hyödyntää, jos eri valmistajien/toimittajien toteutusperiaatteita ei tunneta riittävän hyvin, jotta ne voitaisiin sovittaa toimimaan yhteen?

SSI SCHÄFER on ainoa sisälogistiikan toimittaja, joka tarjoaa kaikkien komponenttien ja järjestelmän osien horisontaalisen ja vertikaalisen integroitavuuden uusien teknologioiden toteutuksen perustaksi: ▶



*WMS (varastonhallintajärjestelmä), MFC (materiaalivirran ohjaus), PLC (ohjelmoitava logiikkaohjain)

Tämä laitteistokomponenttien ja vastaavien ohjelmistotyökalujen integroitu kokonaisuus on perusedellytys, joka sallii tavaravirtaa käsittelevien yksittäisten koneiden paitsi oppia toisiltaan, myös samanaikaisesti arvioida älykkäiden (paikallisten) ohjausjärjestelmien onnistumista korkeamman tason järjestelmiltä tulevan palautteen avulla.

Lisäksi se avaa mahdollisuuden hyödyntää tätä laajennettua teknologiaa soveltuvien algoritmien ja lähestymistapojen täsmäkäyttöön. Motto ”niin paljon paikallisesti kuin mahdollista – keskitetysti niin vähän kuin on pakko – El kompromisseja laatuun tai suorituskykyyn” toimii ohjaavana periaatteena sopivan ennustamisen, ennakoinnin, päätöksenteon ja muiden päätöksiä tukevien työkalujen täsmäkäytössä siellä, missä niiden käyttö on järkevintä ja tuo suurimmat edut.

Kaiken lisäksi tästä integroidusta lähestymistavasta on etua siinä tapauksessa, että tekoäly joutuu sellaisen tilanteen eteen, jollaista se ei ole vielä oppinut. Tällaisessa tapauksessa on mahdollista palata olemassa oleviin perinteisiin, käytössä koeteltuihin ja vakiintuneisiin strategioihin, joissa WAMAS®-varastonhallintaohjelmistoa käytetään päätöksentekoon.

Riippumatta siitä, mitä teknologioita käytetään, optimaalisen, joustavamman ja dynaamisemman varastotoiminnan muodossa asiakkaalle syntyvä etu on se, mikä ratkaisee, ovatko uudet kehitysaskeleet onnistuneita. ■

Legal Notice

Whitepaper
Artificial Intelligence in Logistics

Editor
SSI Schäfer IT Solutions GmbH
Friesachstraße 15
8114 Friesach
Tel. +43 3127 2000
friesach@ssi-schaefer.com

Responsible for the content
SSI Schäfer IT Solutions GmbH
Jacqueline Fauland

All rights reserved.
Reprinting only with the express permission
of the editor.
No liability for printing errors.

Lähteet

Björn Böttcher, Daniel Klemm, Dr. Carlo Velten, Machine Learning im Unternehmenseinsatz - Results of an empirical study in cooperation with The unbelievable Machine Company (*um) and Hewlett Packard Enterprise, Crisp Research, January 2017 (<https://www.crisp-research.com/neue-studie-machine-learning-im-unternehmenseinsatz-kunstliche-intelligenz-als-grundlage-digitaler-trans-formationsprozesse/>) | R. Buchmann, E. Issing, S. Hochrein & M. Bleifuß. The Internet of Things (IoT) within the Intra-logistics Industry, Whitepaper, SSI SCHAEFER 2016 | Ian Goodfellow, Yoshua Bengio, Aaron Courville, Deep Learning, MIT Press, 2016 | McKinsey Global Institute, The age of analytics – Competing in a data-driven world, 2016 (<https://www.mckinsey.com/business-functions/mckinsey-analytics/our-insights/the-age-of-analytics-competing-in-a-data-driven-world>) | Michael Oettinger. Data Science: Eine praxisorientierte Einführung im Umfeld von Machine Learning, künstlicher Intelligenz und Big Data (German Edition), tredition, 2017 | Calvin Seward, Optimizing Warehouse Operations with Machine Learning on GPUs, 2016 (<https://devblogs.nvidia.com/optimizing-warehouse-operations-machine-learning-gpus/>)

Picture credits: S. 3: ©shutterstock, jocic, ©shutterstock, Zerbor | S. 4: ©shutterstock, Tatiana Shepeleva | S. 5: ©shutterstock, Zapp2Photo | S. 15: ©iStock, Chesky_W | S. 16: ©shutterstock, MicroOne

