



jamk

Kunnossapitokustannusten ennustaminen koneoppimismallin avulla

Juho Annala

Opinnäytetyö, ylempi AMK

Huhtikuu, 2024

Elinkaaren hallinta -tutkinto-ohjelma (YAMK)

Annala, Juho

Kunnossapitokustannusten ennustaminen koneoppimismallin avulla

Jyväskylä: Jyväskylän ammattikorkeakoulu. Huhtikuu 2024, 52 sivua

Elinkaaren hallinta -tutkinto-ohjelma. Opinnäytetyö YAMK.

Julkaisun kieli: suomi

Julkaisulupa avoimessa verkossa: kyllä

Tiivistelmä

Työn tilaaja, Remeo Oy halusi tietää, onko kaluston tehokkuutta mahdollista parantaa kustannustehokkaasti. Työ aloitettiin arvioimalla kaluston nykytila, sekä rakentamalla koneoppimismalli ennustamaan kaluston kunnossapitokustannuksia lähivuosille. Ennustemalli käytti hyväkseen Remo Oy:n kaluston olemassa olevaa dataa, kuten ostolaskuja sekä ajotavanseurantajärjestelmän tuottamaa käyttödataa. Tavoitteena oli muodostaa malli, joka pystyy ennustamaan ajoneuvon korvaustarpeen lähivuosille tarkemmin, kuin käytössä olleet keinot. Koneoppimismalli tuotettiin käyttämällä Python-ohjelmointikieltä ja sen Scikit-learn -kirjastoa, joka sisältää useita koneoppimisalgoritmeja. Tutkimuksessa kokeiltiin useita eri malleja ja niiden tuloksia vertailtiin keskenään. Mallin kouluttamiseen käytettiin vuosien 2021 ja 2022 dataa, sekä validointiin vuoden 2023 dataa.

Koneoppimismallin tarkkuus ei riittänyt yksittäisten ajoneuvojen kunnossapitokustannusten ennustamiseen, oletettavasti johtuen datan määrästä ja laatuongelmista, mutta kokonaiskustannusten ennustamiseen se kykeni noin 2 % tarkkuudella vuodelle 2023. Tämä riittää budjetoinnin näkökulmasta, sekä omaisuudenhallintasuunnitelman pohjaksi. Lisäksi malli voitti verratut menetelmät, kun poimittiin 20 kalleinta ajoneuvoa korvattavaksi. Malli siis täytti sille asetetut tavoitteet, mutta sen jatkokehittäminen suuremmalla datamäärällä on vielä suotavaa.

Lisäksi ajoneuvon korvausajankohdan optimointi sidottiin organisaation fyysisen omaisuuden hallintaan ja sen prosesseihin, sekä punnittiin eri hankintamenetelmiä kaluston uusimiseen ottaen huomioon organisaation talouden mittarit.

Avainsanat (asiasanat)

Kalustonhallinta, Omaisuudenhallinta, Kunnossapito, Koneoppimismallit, Korvaussuunnitelma

Muut tiedot (salassa pidettävät liitteet)

Annala, Juho

Fleet maintenance cost forecasting with machine learning models

Jyväskylä: JAMK University of Applied Sciences, September 2020, 52 pages

Degree Programme in Energy and Environmental Technology. Bachelor's thesis.

Permission for open access publication: Yes

Language of publication: Finnish

Abstract

The client, Remeo Oy, wanted to know if it was possible to improve their fleet's efficiency in a cost efficient manner. The project began by assessing the current state of the fleet and by building a machine learning model to predict the fleet's maintenance costs for the coming years. The forecast model utilized existing data from Remeo Oy's fleet, such as purchase invoices and data produced by the driving behavior monitoring system. The goal was to create a model capable of predicting a vehicle's replacement needs in the coming years more accurately than the methods previously used. The machine learning model was developed using the Python programming language and its Scikit-learn library, which includes several machine learning algorithms. Several different models were tested, and their results were compared with each other. The model was trained using data from 2021 and 2022 and validated with data from 2023.

The accuracy of the machine learning model was not sufficient to predict individual vehicle maintenance costs, presumably due to the amount and quality of data, but it was capable of predicting overall costs with about 2% accuracy for 2023. This suffices from a budgeting perspective and as a basis for the asset management plan. Additionally, the model outperformed compared methods when selecting the 20 most expensive vehicles for replacement. Thus, the model met its set goals, but further development with a larger amount of data is still advisable.

Furthermore, the optimization of the vehicle replacement timing was tied to the organization's physical asset management and its processes, and different procurement methods for fleet renewal were weighed, taking into account the organization's financial metrics.

Keywords/tags (subjects)

Fleet management, Physical asset management, Maintenance, Machine learning, Replacement plan

Miscellaneous (Confidential information)

Sisältö

1	Johdanto	4
2	Ongelman kuvaus	5
2.1	Lähtöasetelma	5
2.2	Tutkimusmenetelmä, rajaus ja tavoitteet	6
2.3	Kaluston korvaussuunnitelma ja haasteet	7
2.4	Lähestymistapa	7
2.5	Saatavilla oleva data	9
3	Tavoitteet	10
4	Omaisuu denhallinta yleisesti	12
4.1	Historia	12
4.2	Määritelmä ja laajuus	13
4.3	ISO 55000-standardi ja syyt sen implementointiin	15
4.3.1	ISO 55000 yleisesti	15
4.3.2	ISO 55000	16
4.3.3	ISO 55001	18
4.3.4	ISO 55002	19
4.3.5	ISO 55010	19
4.3.6	Syyt ISO 55000 -standardin implementointiin	20
4.4	Omaisuu denhallintajärjestelmä	21
4.5	Tehokkaan omaisuu denhallinnan hyödyt	23
5	Elinjakso ja sen vaiheet	24
6	Kaluston korvaus ja kustannusennuste osana omaisuu denhallintaa	27
6.1	Kaluston korvaamisella tavoitellut hyödyt	27
6.2	Korvaus-ajankohta	27
7	Mallit kustannusten arviointiin	32
7.1	Koneoppimismallit	32
7.2	Regressiomallit	33
7.2.1	Support Vector Regression (SVR)	34
7.2.2	EnsembleRegressors	34
7.2.3	Ridge, Lasso ja ElasticNet	35
7.3	Python ja SKLearn	37
8	Malli, sen toiminta ja tulokset	38
8.1	Datan lähteet, formaatti ja validointi	38

8.2	Random Forest Regressor-mallin tulokset.....	41
8.3	Muut mallit.....	43
8.4	Tulokset	43
8.5	Mallin käyttö korvauspäätöksen tukena.....	46
9	Pohdintaa.....	47
9.1	Kuljetusalan kustannusrakenne suomessa	47
9.2	Eri hankintamallit ja niiden vaikutukset talouden mittareihin	48
9.2.1	Rahoituksen vaihtoehdot	48
9.2.2	Vaikutus kirjanpidossa	50
9.3	Koneoppimismallin käyttö tulevaisuudessa.....	52
9.4	Muut lähestymistavat	53
9.5	Mallin käyttö korvaussuunnitelman optimoinnin tukena	53
9.5.1	Optimointiongelman luokittelu	53
9.5.2	Ratkaisumenetelmät.....	54
9.5.3	Ratkaistavan ongelman määrittely.....	55
	Lähteet	57
	Liitteet	60
	Liite 1. Ennustemallin tulokset	60
	Liite 2. Koodi.....	63
	Liite 3: Data	69
	Liite 4: Muiden kokeiltujen mallien pisteytykset	71
	Kuviot	
	Kuvio 1: Datan analysointiprosessi DIKW-hierarkia(Kortelainen, Komonen & Laitinen 2021)	8
	Kuvio 2: Käyttövarmuuden osatekijöiden merkitys käyttövaiheen kustannusten muodostumisessa (Kortelainen ym. 2021)	9
	Kuvio 3: Kilometrisuoritteiden kehitys ajoneuvon ikääntyessä.....	12
	Kuvio 4: PAS 55:n kuvaus omaisuudenhallintajärjestelmästä (PAS 55-1 2008, 7)	15
	Kuvio 5: Käsiteiden väliset suhteet ISO 55000 standardissa (ISO 55000:2014)	17
	Kuvio 6: Omaisuudenhallintajärjestelmä ISO 55000 -standardin mukaan (ISO 55000:2014, 42)23	
	Kuvio 7: Geneerinen elinjaksomalli ((IEC 60300-1 2014) kuten ilmaistu teoksessa Tietämysperusteinen Elinjaksonhallinta (Kortelainen ym. 2021)).....	25
	Kuvio 8: Elinjakson vaiheet omistajan näkökulmasta (Hastings 2010).....	26
	Kuvio 9: Korvausanalyysi - tasaisesti nousevat kustannukset (Hastings 2010)	29
	Kuvio 10: Epätasaisesti nousevat kustannukset (Hastings 2010)	30

Kuvio 11: Ajoneuvon iän vaikutus kustannuksiin.....	32
Kuvio 12: "SKLearn cheat sheet" https://scikit-learn.org/stable/tutorial/machine_learning_map/index.html	33
Kuvio 13: Ajettavien kilometrien ja ajoneuvotyyppin vaikutus €/km -kustannuksiin	40
Kuvio 14: Ajoneuvojen vuosittaisten kustannusten muutokset ikävuosittain vuosien 2021 ja 2022 välillä	41
Kuvio 15: Ennustemallin ajoneuvokohtainen tarkkuus	44
Kuvio 16: Satunnaisesti poimittujen ajoneuvojen kustannukset	45
Kuvio 17: Kuljetusyritysten kaluston kustannusjakauma eri segmenteissä ((Tilastokeskus 2023) kuten ilmaistu Läpinäkyvää logistiikkaa -uutiskirjeessä (Sundström 2023)).	48

Taulukot

Taulukko 1: Muuttujien vaikutukset ennustemalliin Random Forest Regressor-mallilla.....	42
Taulukko 2: Random Forest Regressor -mallin pisteytys.....	43
Taulukko 3: Datamalli edellisen vuoden kustannuksilla	70
Taulukko 4: Anonymisoitu datamalli	70
Taulukko 5: SVR-mallin pisteytys	71
Taulukko 6: ElasticNet-mallin pisteytys	71
Taulukko 7: Lasso-mallin pisteytys.....	71
Taulukko 8: Ridge-mallin pisteytys	71
Taulukko 9: Gradient Boosting Regressor -mallin pisteytys	71

1 Johdanto

Fyysisen omaisuuden hallinta on noussut kriittiseksi tieteenhaaraksi organisaatioille eri aloilla, kuten tuotevalmistuksessa, infrastruktuurissa, energiassa ja liikenteessä. Fyysisen omaisuuden hallinnan kasvava merkitys voidaan liittää useisiin tekijöihin, kuten omaisuuden kasvavaan monimutkaisuuteen, tarpeeseen optimoida omaisuuden suorituskykyä ja minimoida kustannuksia, sekä säädösten vaatimukseen turvallisuuden ja ympäristön osalta.

Kansainvälisten standardien, kuten ISO 55000 -sarjan, kehittäminen on myös ollut ratkaisevassa asemassa fyysisen omaisuuden hallinnan edistymisessä. Nämä standardit tarjoavat viitekehyksen organisaatioille tehokkaan omaisuuden hallintajärjestelmän perustamiseen, toteuttamiseen, ylläpitämiseen ja parantamiseen. ISO 55000 -sarja, joka esiteltiin vuonna 2014, on saanut laajaa tunnustusta ja hyväksyntää maailmanlaajuisesti, auttaen organisaatioita sovittamaan omaisuudenhallintakäytäntönsä globaaleihin parhaisiin käytäntöihin. Nykyään fyysisen omaisuuden hallinta tunnustetaan strategiseksi toiminnoksi, joka edistää organisaation kokonaisuuden menestystä. Tehokas omaisuuden hallinta mahdollistaa organisaatioiden hyödyntää omaisuutensa arvoa, vähentää kustannuksia, parantaa turvallisuutta ja luotettavuutta sekä lisää asiakastytyvääisyyttä. Koska fyysisen omaisuuden merkitys jatkaa kasvuaan modernissa taloudessa, fyysisen omaisuuden hallinnan ala odotetaan kehittyvän edelleen, omaksuen uusia teknologioita ja parhaita käytäntöjä jatkuvan parantamisen ja optimoinnin edistämiseksi. (Asset Management - An Anatomy 2015).

Liikenteen alalla liikkuvan kaluston kunnossapidolla on keskeinen rooli osana organisaatioiden toimintaa, sillä se vaikuttaa suoraan ajoneuvojen käyttöikään ja turvallisuuteen. Kunnossapidon kustannusten ennustaminen taas on olennaista oikea-aikaisen korvaamisen näkökulmasta, mikä voi vaikuttaa suuresti organisaation taloudelliseen suorituskykyyn ja tehokkuuteen. Tässä työssä tarkastellaan, miten koneoppimismallin hyödyntäminen voi parantaa liikkuvan kaluston kunnossapitokustannusten ennustamista verrattuna perinteisiin menetelmiin. Lisäksi tarkastellaan, miten nämä ennustamismenetelmät liittyvät ISO 55000 -standardin mukaiseen omaisuudenhallintaan ja sen periaatteisiin, sekä miten organisaatio voi hyötyä kunnossapitokustannusten ennustamisesta ja liikkuvan kaluston strategisesta korvaamisesta.

Menetelmänä käytettiin tutkivaa kehittämistä, mikä on iteratiivinen prosessi, jossa teoria ja käytäntö kulkevat rinnakkain tietämyksen kartuttamiseksi ja konkreettisten ratkaisujen löytämiseksi

(Toikko & Rantanen 2009). Tutkiva kehittäminen soveltuu työhön erinomaisesti, sillä se mahdollistaa jatkuvan oppimisen ja sopeutumisen projektin edetessä, ja se tuki erityisesti sellaisen toimintamallin kehittämistä, jossa koneoppimisen antamat ennusteet voitiin integroida suoraan ajoneuvokaluston hallintaprosesseihin. Tämän lähestymistavan ansiosta työ ei ainoastaan tuottanut teoreettista tietoa koneoppimisen soveltuvuudesta ajoneuvokaluston hallintaan, vaan myös konkreettisen toimintasuunnitelman, joilla voidaan saavuttaa merkittäviä säästöjä Remeo Oy:n operatiivisessa toiminnassa.

2 Ongelman kuvaus

2.1 Lähtöasetelma

Remeo Oy on ympäristöalan logistiikkayritys, joka on liikevaihdoltaan noin 92 miljoonaa (2021). Yrityksen käytössä on noin 220 raskaan ajoneuvon laivue, joka koostuu useasta eri merkistä ja mallista, ikäluokasta, sekä päälirakenteesta. Ajoneuvot liikennöivät usealla eri paikkakunnalla ja erilaisissa toimintaympäristöissä, syrjäseutujen sorateillä ja suurimpien kaupunkiemme keskustoissa. Kaluston kirjavuus aiheuttaa ongelmia kalustonhallinnan näkökulmasta, erilaisilla ja eri käyttötarkoituksissa olevilla ajoneuvoilla voi olla hyvin eri mittainen elinjakso. Remeo Oy:n kaluston kunnossapitokustannukset olivat korkeat ja vanheneva kalusto aiheutti katkoksia työn suorittamiseen viikaantumisillaan. Jotta yritys pääsee tavoiteltuun liikevaihdon kasvuun, on kalustoa uusittava. Tätä varten on selvitettävä, kuinka paljon kalustoa yritys oikeasti tarvitsee liiketoimintansa suorittamiseksi, jos kalusto olisi uutta ja mikä on kustannustehokkain tahti uusia tarvittava määrä kalustoa.

Ajoneuvokaluston korvaustahtia ohjaa myös budjetti. Osana korvaussuunnitelmaa oli esitettävä, kuinka Remeo Oy voi korvata kalustoaan mahdollisimman tehokkaasti ennalta määrätyn budjetin raameissa, käyttäen hyväkseen myös markkinoilla olevia rahoitus- ja leasing-vaihtoehtoja, ja miten nämä vaihtoehdot vaikuttavat talouden mittareihin, kuten EBITDA:han, eli Earnings Before Interest, Taxes, Depreciation & Amortization, joka tarkoittaa tulosta ennen korkoja, veroja poistoja ja arvenalentumista. Tämä on yksi yleisesti käytetty mittari, jolla arvioidaan yrityksen taloudellista tilaa. (Käyttökate - mitä tarkoittaa käyttökate? (EBITDA) 2024)

2.2 Tutkimusmenetelmä, rajaus ja tavoitteet

Opinnäytetyössä esitellään ensin ratkaistava ongelma, sen lähtökohdat ja tavoitteet. Tämän jälkeen kuvaillaan ISO 55000 -standardin rooli omaisuudenhallinnassa ja sen yhteys kunnossapitokustannusten hallintaan ja oikea-aikaiseen kaluston korvaamiseen, sekä työssä käytetyt menetelmät ja analyysit, sekä tulokset ja niiden merkitys liiketoiminnalle. Tutkimuksen tulokset ja johtopäätökset esitetään lopuksi, sekä käydään läpi menetelmiä, millä tavoin organisaatiot voivat hyödyntää tämän kaltaista ennustemallia omaisuudenhallinnan prosesseissaan.

Työn tilaajana toimi Remeo Group Oy ja sen tavoite oli tukea organisaatiota kaluston korvaushankinnan suunnittelussa. Tutkimus keskittyy koneoppimisen hyödyntämiseen ajoneuvokaluston huoltokustannusten ennustamisessa. Tavoitteena oli kehittää strategia, joka maksimoi Remeo Oy:n kaluston operatiivisen tehokkuuden ja minimoi kustannukset. Tutkimuskysymyksinä olivat:

1. Voiko olemassa olevalla datalla ennustaa kunnossapitokustannusten kehittymistä riittävällä tarkkuudella
2. Voiko ennustemallia käyttää tehokkaan strategisen kalustokorvaussuunnitelman kehittämiseen

Tutkimuksessa hyödynnettiin olemassa olevaa dataa ajoneuvoista, kuten kunnossapitokustannuksia, ajokilometrejä ja ajoneuvotietoja, ja analysoitiin tämän tiedon avulla kaluston operatiivista tehokkuutta. Analyysin perusteella ilmeni, että tietyt vähän käytetyt ajoneuvot ovat operatiivisesti tehottomia, mutta niiden korvaaminen uusilla ei olisi kustannustehokasta. Tämän vuoksi oli tarpeen ennustaa 6–13 vuoden ikäisten ajoneuvojen kustannuskehitys, joiden kunnossapitokustannuksilla oli suuri riski nousta merkittävästi suuremmaksi lähivuosina. Ennusteen avulla pystyttiin identifioimaan korkeimmat kustannukset aiheuttavat ajoneuvot, jotka oli syytä korvata uusilla ajoneuvoilla. Näitä Vanhemmat ajoneuvot korvattiin puolestaan näillä poistetuilla ajoneuvoilla, ja kaikkein vanhimmat ajoneuvot joko romutettiin tai myytiin, jolloin maksimoitiin uuden kaluston vaikutus kaluston keski-ikäen.

Työn tulokset perustuvat Remeo Oy:n vuosilta 2021 ja 2022 kerättyihin kunnossapitokustannuksiin, jotka toimivat koneoppimismallin koulutusdatana. Mallin validointiin käytettiin vuoden 2023

kunnossapitokustannuksia. Koneoppimismalli osoittautui lupaavaksi työkaluksi strategisen korvaussuunnitelman teossa, kun sitä verrattiin perinteiseen toimintatapaan, jossa korvaamisen päätökset tehdään edellisvuoden kalleimpien ajoneuvojen perusteella, tai perinteiseen malliin, missä ajoneuvo korvataan, kun sitä ei enää voi korjata.

2.3 Kaluston korvaussuunnitelma ja haasteet

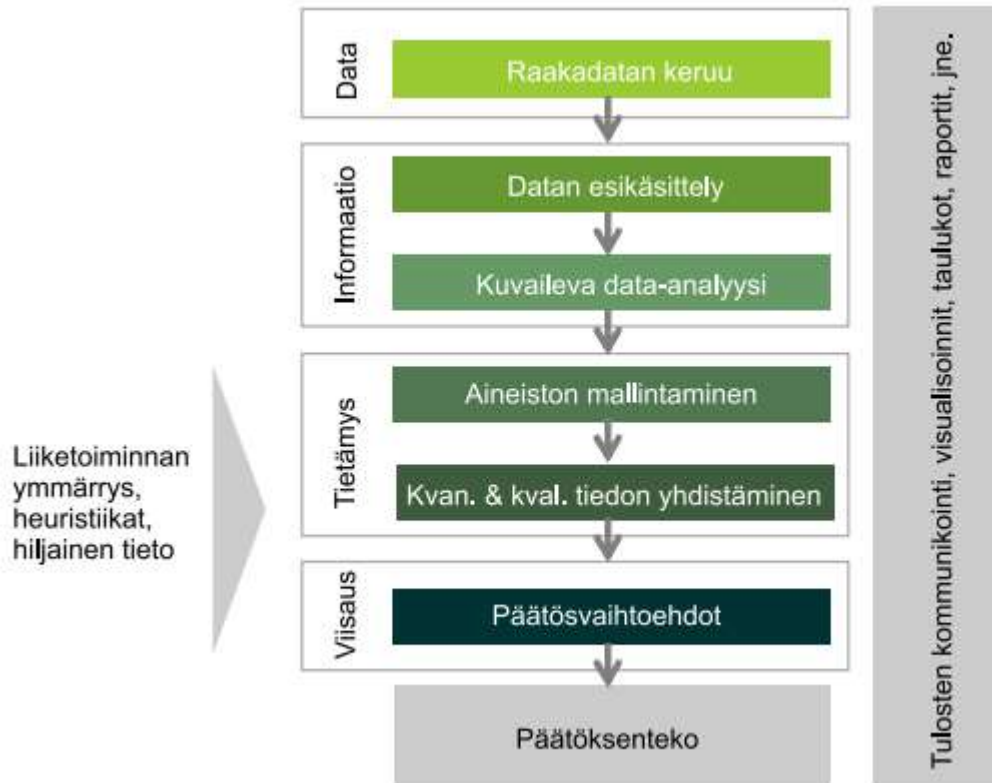
Kaluston uusimisessa haasteeksi nousee ympäristöalan käyttämien ajoneuvotyyppien harvinaisuus. Käytettyjen ajoneuvojen markkinat ovat melko pienet, eivätkä maahantuojat pidä jäteajoneuvoja juurikaan varastossa. Tämän seurauksena vanhan ajoneuvon korvaava laite on tilattava hyvissä ajoin, mielellään vähintään vuosi ennen, kuin kyseisen ajoneuvon korvaaminen on ajankohtainen, erikoisemmissa ajoneuvoissa jopa kaksi vuotta ennen. On hyvin mahdollista, että vuoden aikana sattuu myös jotain odottamatonta, kuten liikenneonnettomuus, tulipalo tai ilkkivaltaa, jonka seurauksena käytössä oleva kalustomäärä laskee. Liian varovainen arvio tulevan vuoden korvaustarpeista voi siis johtaa kalustopulaan, kun taas liian rohkea korvaustahti johtaa ylimääräiseen kalustoon ja sitä kautta korkeampiin kalustokustannuksiin. Suuri määrä korvattavia ajoneuvoja on myös suuri kuluerä, hankittiin se sitten rahoituksella tai omalla pääomalla. Hankintasuunnitelma on siis perusteltava tarkoin sekä kulujen, että tuottojen osalta.

Yhdeksi haasteeksi muodostuu myös seisonta-ajan kokonaiskustannusten laskeminen. Kaluston kunnossapidon kuluja voidaan seurata ajoneuvokohtaisesti, mutta korvaussuunnitelmaa tehdessä olisi otettava huomioon myös vikaantumisesta seuranneen mahdollinen liikevaihdon menetys ja sanktiot, sekä oheiskulut, kuten kuljettajan menetetty työaika. Tälle ei ole olemassa helppoa laskentatapaa, sillä kulut ovat tapauskohtaisia riippuen ajankohdasta, kaluston tyypistä ja muista muuttujista. Mikäli käytettävyysongelmat johtavat usein alihankinnan käyttämiseen, voidaan seisonta-ajan kustannukseksi valita alihankkijan tuntihinta.

2.4 Lähestymistapa

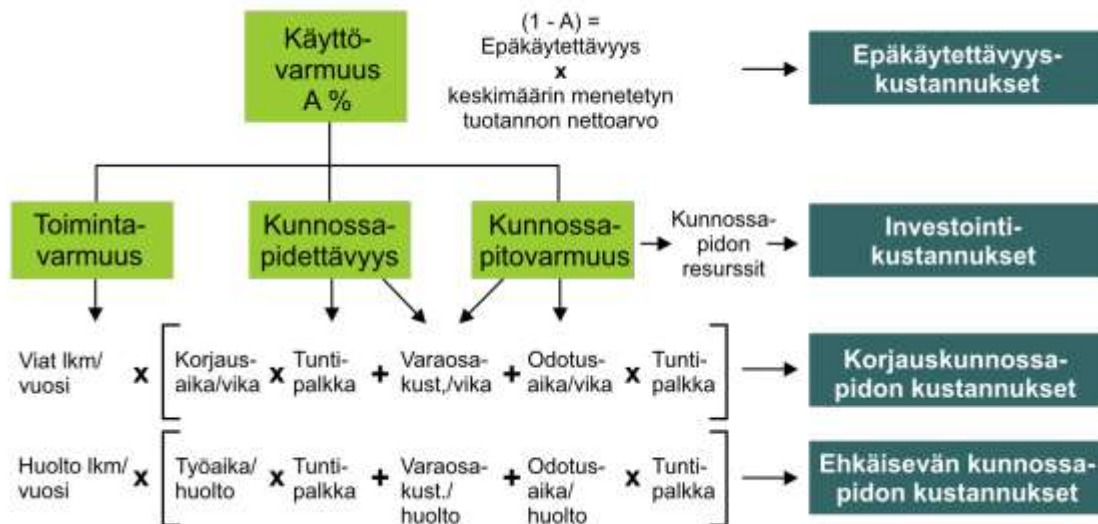
Jotta voidaan optimoida kaluston korvausajankohta ottaen huomioon uuden kaluston toimitusajat, täytyy pyrkiä ennustamaan kaluston käyttökustannuksia tuleville vuosille, sekä kaluston jäännösarvoa ja uuden vastaavan hankintakustannusta korvaushetkellä. Käyttökustannusten ennustamiseen käytetään koneoppimisalgoritmia, sekä toimeksiantajayrityksen omaa kustannusdataa.

Työkaluina koneoppimismallissa käytetään Python-ohjelmointikieltä ja sen Pandas, Numpy ja SKLearn-kirjastoja. Työn eteneminen noudatti DIKW-hierarkiaa, kuten se on kuvattu Kuvio 1:ssä.



Kuvio 1: Datan analysointiprosessi DIKW-hierarkia(Kortelainen, Komonen & Laitinen 2021)

Kunnossapitokustannuksien lisäksi tärkeää on laskea seisonta-ajan kustannukset. Kuvio 2 kuvaa epäkäytettävyyuskustannuksien laskentakaavan kuten ne on kirjassa Tietämysperusteinen Elinjaksonhallinta (Kortelainen ym. 2021) kuvattu. Seisonta-ajoista ei ollut työn alkaessa saatavilla luotettavaa dataa, joten seisonta-ajan kustannukset määritellään olemassa olevalla datalla. Seisonta-ajasta johtuva kustannus sidotaan kunnossapitokustannuksiin siten, että kaluston kunnossapitokustannuksia ja seisonta-aikaa seurattiin määräajan ja tästä laskettiin keskiarvo seisonta-aika (h) / kunnossapito (€). Tämän jälkeen ennustettaessa kokonaiskustannuksia ennustettu seisonta-aika lasketaan ennustetusta kunnossapitokustannuksesta, ja kerrotaan seisonta-ajan arvioidulla tunti-hinnalla.



Kuvio 2: Käyttövarmuuden osatekijöiden merkitys käyttövaiheen kustannusten muodostumisessa (Kortelainen ym. 2021)

2.5 Saatavilla oleva data

Nykytilanteessa käytössä on vain kunnossapitokustannukset vuositasolla ajoneuvokohtaisesti, perustiedot kuten ikä, ajetut kilometrit ja ajoneuvon tyyppi, yksikkö, sekä korvauskustannus, ajoneuvon jäännösarvio ja tasearvo. Arvio korvaustarpeista on siis tehtävä näillä tiedoilla, joka kasvattaa riskiä huonoista päätöksistä korvaussuunnitelman teossa. Tilannetta kuitenkin lievittää hiljainen tieto, jota eri yksiköiden edustajilla on, ja tätä oli syytä hyödyntää iteroimalla suunnitelmaa heidän kanssaan.

Saatavilla oleva datakaan ei ole täydellistä. Kunnossapitokustannustiedot ovat kooste kunnossapitajien laskuista ja näiden käsittelyketjussa on monta ihmistä. On siis tavanomaista, että laskuja kirjataan väärin, joko väärälle ajoneuvolle tai väärälle tilille, joka alentaa datan luotettavuutta. Tähän vaikuttaa myös kunnossapitotoimijoiden tapa laskuttaa työt yhdellä laskulla, vaikka ne sisältäisivät eri työtyyppejä, kuten vauriokorjausta ja kunnossapitoa. Myös ajoneuvon käyttödataa oli työn tekoheikällä liian vähän. Itse järjestelmässä oli ongelmia, joiden seurauksena useiden ajoneuvojen käyttödata oli heikotasoista, jonka seurauksena se jätettiin pois ennustemallista. Mikäli käyttödataa on saatavilla, se on suotavaa ottaa mukaan, esimerkiksi määrittelemällä ajotavalle pisteytys, niillä mittareilla ja painoarvoilla, mitkä ovat liiketoiminnan tyyppi huomioon ottaen tärkeitä. Kuljettajan ajotavan negatiivisesta vaikutuksesta kunnossapitokustannuksiin on tehty jonkin verran

tutkimuksia, esimerkiksi Iso-Britanniassa paikallisen autoliiton koulutusyhtiön, DriveTechin toimesta. (Drivetech 2020).

Tärkeimmät datan lähteet olivat taloushallinnon raportointijärjestelmä, ajotavan seurantajärjestelmä ja kalustorekisteri. Näistä saatiin ajoneuvo kohtaista kustannusdataa, ajoneuvon kilometrisuoritteet ja mittarilukemat, sekä ajoneuvon perustiedot. Kustannusdatasta täytyi ensin siivota muun muassa vauriokustannukset pois, koska voidaan olettaa niiden johtuvan jostain muusta, kuin ajoneuvon ikääntymisestä. Esimerkkejä näistä ovat kolarit ja ojaan ajot. Kilometrisuoritteista oli myös siivottava käyttökeltotonta dataa. Varsinkin vanhempien ajoneuvojen lähettämässä dataassa oli usein virheitä, jolloin kilometrejä jäi kirjaamatta, tai niitä kirjattiin poikkeuksellisen paljon. Kalustorekisterissä oli puutteita, mutta tätä tarkoitusta varten se sisälsi kaiken tarvittavan tiedon

3 Tavoitteet


Tavoitteena työllä on saada aikaan ennustemalli, joka ennustaa kaluston kunnossapitokustannusten kehityksen, jotta saadaan aikaan tehokas tapa korvata käytöstä poistuvaa kalusto oikea-aikaisesti, ennen kuin kustannukset nousevat liikaa ja ajoneuvon käytettävyys kärsii. Mallin tehokkuutta verrataan kahta eri korvausstrategiaa vastaan:

1. Ajoneuvo korvataan, kun sen vuosittaiset kunnossapitokustannukset ylittävät 100 % uuden vastaavan vuosittaisista rahoitus- ja huoltosopimuskustannuksista
2. Ajoneuvokannasta korvataan vuosittain kunnossapitokustannuksiltaan kalleimmat 10 %

Ensimmäinen korvausstrategia vastaa Remeo Oy:n aikaisempaa käytäntöä, jossa ajoneuvo uusitaan, kun se nähtiin liian kalliiksi korjata, eli kun uuden ajoneuvon hankkiminen oli selkeästi halvempi vaihtoehto, tai vanha ajoneuvo koettiin olevan kykenemätön suorittamaan tehtäväänsä. Toisen korvausstrategian ratkaisevana tekijänä ovat ainoastaan kunnossapitokustannukset, samoin kuin koneoppimismallia käyttävässä korvausstrategiassa. Erona kuitenkin se, että kyseinen strategia on hyvin yksinkertainen toteuttaa, eikä se vaadi kustannusten ennustamista.

Korvaussuunnitelman tehokkuuden mittarina käytetään kokonaiskustannuksia, sisältäen kunnossapidon ja rahoitusosuuden, suhteutettuna ajettuihin kilometreihin [€/km]. Kunnossapitokustannuksiin lasketaan vain ajoneuvolle kirjatut kuluvien osien korjaukseen ja määräaikaishuoltoihin kirjatut kustannukset. Kustannuksiin ei lasketa onnettomuuksista aiheutuneita vaurioita. Vertailuun ja mallintamiseen käytetään edellisen kolmen vuoden dataa kunnossapitokustannuksista ja oletetaan, että uudet korvaavat ajoneuvot hankitaan kunnossapitosopimuksilla, jolloin niiden kunnossapitokustannukset pysyvät vakiona sopimuksen ajan.

Ennustemallin ulkopuolelle rajataan kulut, jotka eivät suoraan tai merkittävästi riipu kaluston vanhenemisesta, kuten polttoainekustannukset, vauriot ja renkaat. Vaikka nämä ovat merkittäviä osuuksia kaluston kokonaiskustannuksista, ne ovat enemmän riippuvaisia esimerkiksi kilometrisuoritteesta ja käyttötunneista, kuin kaluston iästä. Sen sijaan korvaussuunnitelmaa tehdessä nämä on syytä ottaa huomioon, esimerkiksi vertaamalla korvattavan ja korvaavan ajoneuvon polttoaineen keskikulutusta. Ennustemalli toteutetaan Python-ohjelmointikielen SKLearn-kirjaston koneoppimisalgoritmeilla, ja mallin tavoite on ennustaa eri ikäluokan ja kilometrisuoritteen omaavan ajoneuvon kunnossapitokustannuksia per kilometri. Mallin käyttämä kilometrisuorite on kalustolle budjetoitu vuosittainen kilometrisuorite, joka riippuu ajoneuvon käyttökohteesta. Käytännössä ajoneuvon kilometrisuorite alkaa pienenemään vuosittain (Kuvio 3) samalla, kun ajoneuvon kunnossapitokustannukset nousevat. Siksi ennustemallin kohteeksi valittiin €/km, jolloin voimme osaltaan ottaa huomioon myös käytettävyyden laskun. Mikäli organisaatio pystyy mittaamaan ajoneuvokohtaista tuottoa riittävällä tarkkuudella, voi olla tarkoituksenmukaista käyttää sitä kilometrien sijaan.



Kuvio 3: Kilometrisuoritteen kehitys ajoneuvon ikääntyessä

4 Omaisuuksienhallinta yleisesti

4.1 Historia

The Institute of Asset Management (IAM) kertoo termin Asset Management (omaisuudenhallinta) syntyneen 1980-luvulla, Yhdistyneessä Kuningaskunnassa Piper Alpha öljynporauslautan onnettomuuden jälkeen. Onnettomuutta seuranneiden tutkimusten jälkeen perustettiin öljynporauslaitoille poikkitieteelliset ryhmät hallinnoimaan kyseisen omaisuuserän koko elinkaarta. Tällä pyrittiin kasvattamaan tuottavuutta ja tehokkuutta, sekä hallitsemaan riskejä. Samaan aikaan muualla maailmassa julkisella sektorilla havahduttiin ongelmiin omaisuudenhallinnassa ja kehitettiin käytäntöjä, miten ottaa huomioon koko elinkaaren kustannukset huomioon hankintavaiheessa. (Asset Management - An Anatomy 2015)

Vuonna 2004 IAM tuotti PAS 55:n, jonka British Standards Institution (BSI) julkasi. PAS 55:n tavoitteena oli määritellä omaisuudenhallinta ja omaisuudenhallintajärjestelmä ja tarjota organisaatiolle selkeä opas ja esimerkkejä omaisuudenhallintansa kehittämiseksi. (PAS 55-1 2008). PAS 55:n uudistettua 2008 versiota oli rakentamassa 50 organisaatiota 10 eri maasta ja useilta eri toimialoilta.

PAS 55 johti osaltaan kansainväliseen ISO 55000-standardiin, joka julkaistiin vuonna 2014. Standardi sisälsi kolme osaa:

1. 55000 – Yleiskuvaus, periaatteet ja termit
2. 55001 – Hallintajärjestelmä ja vaatimukset
3. 55002 – Ohjeita standardin ISO 55001:2014 soveltamisesta

Julkaisunsa jälkeen ISO 55000 on noussut johtavaksi omaisuudenhallinnan standardiksi. Standardia kehitetään jatkuvasti ISO/TC251 teknisen komitean toimesta, johon kuuluu osallistujia 35 eri maasta (ISO/TC251 Contact 2024).

4.2 Määritelmä ja laajuus

ISO 55000 kuvaa omaisuudenhallinnan seuraavalla tavalla:

”organisaation koordinoitu toiminta, jolla hyödynnetään omaisuuden arvo” (ISO 55000:2014, 36).

Hastings taas määrittelee omaisuudenhallinnan kirjassaan Physical Asset Management (Hastings 2010) eräksi aktiviteetteja, jotka liittyvät:

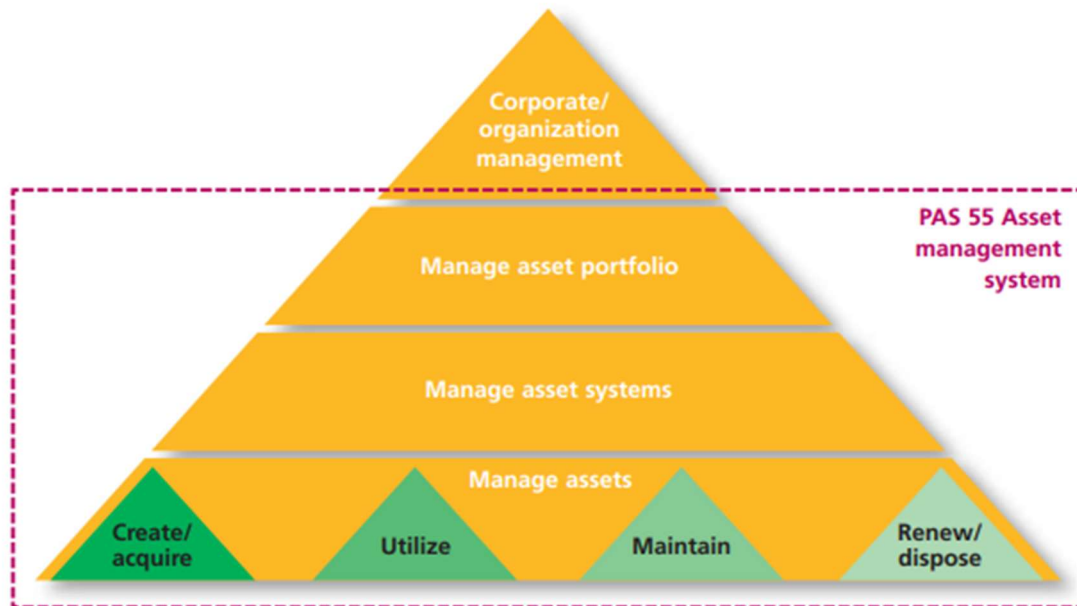
- Tarvittavien omaisuuserien tunnistamiseen
- Tarvittavan rahoituksen määrittämiseen
- Omaisuuserien hankkimiseen
- Logistisen ja kunnossapidon tuen antamiseen omaisuuserille
- Omaisuuserien hävittämiseen tai uusimiseen organisaation tavoitteiden täyttymisen edellyttämällä tavalla

Määritelmän mukaan omaisuudenhallinta käsittää monta osa-aluetta ja osaamista usealta eri aihealueelta. Fyysisen omaisuuden hallinnan tavoitteena on optimoida omaisuuserien suorituskyky,

luotettavuus ja pitkäikäisyys samalla kun kustannukset ja riskit minimoidaan. Keskeisiä aihealueita ovat:

- Suunnittelu
 - Organisaation tavoitteiden saavuttamiseksi tarvittavien omaisuuserien tunnistaminen ja strategioiden kehittäminen niiden hankintaan, ylläpitoon ja hävittämiseen.
- Hankinta
 - Tarvittavien omaisuuserien hankkiminen ottaen huomioon tekijät kuten kustannukset, laatu ja yhteensopivuus olemassa olevien järjestelmien kanssa.
- Käyttö ja ylläpito
 - Varmistetaan, että omaisuutta käytetään tehokkaasti ja tehokkaasti, ja toteutetaan ehkäisevät ja korjaavat huolto-ohjelmat.
- Seuranta ja arviointi
 - Arvioidaan säännöllisesti omaisuuden suorituskykyä ja kuntoa tunnistamaan mahdolliset ongelmat ja parannusmahdollisuudet.
- Uusiminen ja hävittäminen
 - Päätetään milloin korjata, päivittää tai korvata omaisuuserät niiden kunnan, suorituskyvyn ja organisaation tarpeiden perusteella, sekä hävitetään asianmukaisesti omaisuuserät, joita ei enää tarvita.
- Riskienhallinta
 - Tunnistetaan ja lievennetään omaisuuden omistamiseen ja käyttöön liittyviä riskejä, kuten turvallisuusriskit, ympäristövaikutukset ja taloudelliset riskit.
- Tiedonhallinta
 - Kerätään, analysoidaan ja käytetään tietoa omaisuudesta päätöksenteon tueksi ja omaisuuden suorituskyvyn optimoimiseksi.

(Hastings 2010; ISO 55000:2014)



Kuvio 4: PAS 55:n kuvaus omaisuudenhallintajärjestelmästä (PAS 55-1 2008, 7)

4.3 ISO 55000-standardi ja syyt sen implementointiin

4.3.1 ISO 55000 yleisesti

Fyysisen omaisuuden hallinta ISO 55000 -standardin mukaisesti on järjestelmällinen lähestymistapa, joka auttaa organisaatioita hallitsemaan ja optimoimaan fyysisiä varojaan tehokkaasti. ISO 55000 on kansainvälinen standardi, joka tarjoaa peruseräkkeet ja suositukset fyysisen omaisuuden hallinnalle ja auttaa organisaatioita saavuttamaan parempaa taloudellista suorituskykyä ja pitkän aikavälin arvoa fyysiselle omaisuudelleen. Standardi painottaa myös riskienhallintaa ja kestävä kehitystä.

ISO 55000 standardi koostuu seuraavista kokonaisuuksista:

- Johtaminen ja organisaatio: Standardi korostaa organisaation johdon roolia ja sitoutumista fyysisen omaisuuden hallintaan. Organisaation tulisi nimetä vastuuhenkilöt ja määrittää selkeät roolit ja vastuut fyysisen omaisuuden hallinnassa (ISO 55000:2014).
- Strateginen suunnittelu: Organisaation tulisi määrittää fyysisen omaisuuden hallinnan strategiset tavoitteet ja suunnitelmat, jotka tukevat liiketoiminnan tavoitteita. Tämä sisältää omaisuuden elinkaaren hallinnan ja riskienhallinnan (ISO 55000:2014).

- Toimeenpano ja toiminta: Organisaation tulee toteuttaa strategiansa käytännössä. Tämä sisältää resurssien allokaation, prosessien suunnittelun ja toteutuksen, tietojen keräämisen ja analysoinnin sekä korjaavat toimenpiteet tarvittaessa (ISO 55000:2014).
- Suorituskyvyn mittarit ja seuranta: Standardi painottaa suorituskyvyn mittareiden ja avaintunnuslukujen käyttöä fyysisen omaisuuden seurannassa. Organisaation tulee arvioida säännöllisesti, kuinka hyvin se saavuttaa asetetut tavoitteet ja tehdä tarvittavat parannukset (ISO 55000:2014).
- Tiedonhallinta: Organisaation on huolehdittava siitä, että sillä on riittävästi tietoa fyysisestä omaisuudestaan, mukaan lukien dokumentaatio, tekniset tiedot ja historiatiedot. Tietoja on ylläpidettävä ja hallittava järjestelmällisesti (ISO 55000:2014).
- Riskienhallinta: Standardi kannustaa organisaatioita tunnistamaan ja hallitsemaan riskejä, jotka liittyvät fyysiseen omaisuuteen. Tämä voi sisältää esimerkiksi turvallisuusriskejä, ympäristöriskien hallintaa ja liiketoimintariskejä (ISO 55000:2014).
- Päätöksenteko: Fyysisen omaisuuden hallinnan tulisi tukea organisaation päätöksentekoa, erityisesti päätöksiä liittyen investointeihin, korjauksiin ja korvaaviin hankintoihin. Päätökset tulisi tehdä tietoon perustuen (ISO 55000:2014).
- Jatkuvan parantamisen periaate: ISO 55000 kannustaa organisaatioita jatkuvaan parantamiseen. Tämä tarkoittaa, että prosesseja ja käytäntöjä tulee tarkastella ja päivittää säännöllisesti paremman suorituskyvyn saavuttamiseksi (ISO 55000:2014).

Kokonaisuudessaan ISO 55000-standardi auttaa organisaatioita kehittämään tehokkaampaa fyysisen omaisuuden hallintaa, mikä voi parantaa liiketoiminnan tuottavuutta, vähentää riskejä ja lisätä omaisuuden pitkän aikavälin arvoa. Standardi tarjoaa viitekehysten, joka voi soveltua monenlaisille organisaatioille ja fyysisen omaisuuden tyypeille, kuten teollisuuslaitoksille, infrastruktuuri-projekteille ja kiinteistöille.

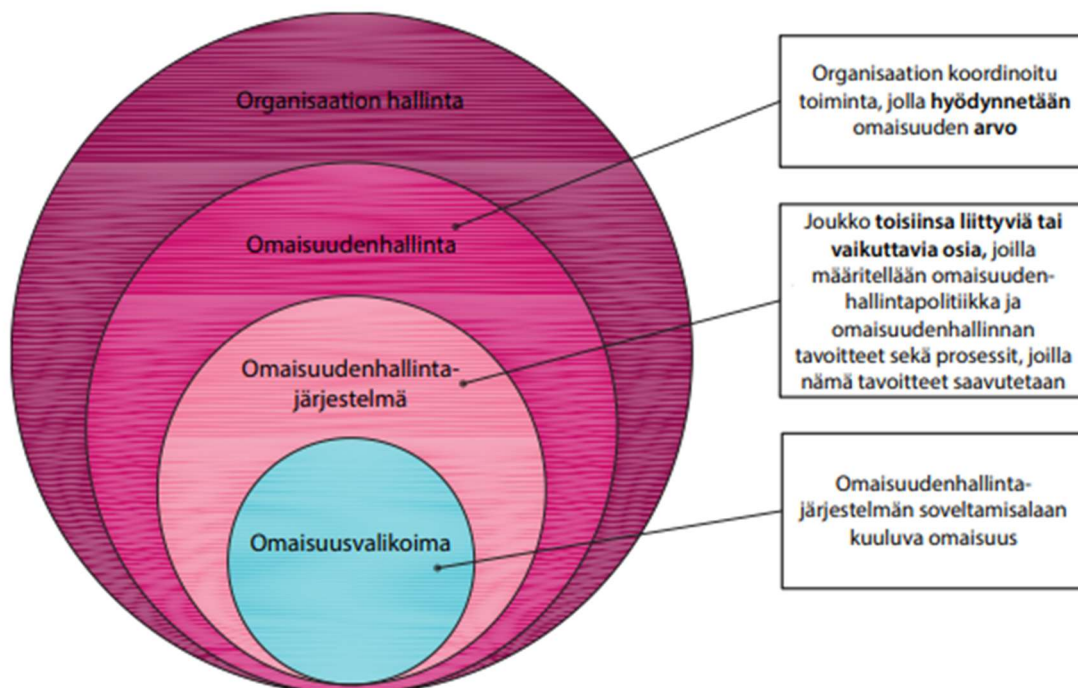
4.3.2 ISO 55000

ISO 55000 tarjoaa yleiskatsauksen omaisuuden hallinnan käsitteistä, periaatteista ja terminologiasta. Sen tavoitteena on selventää omaisuuden hallinnan käsitteellistä viitekehystä ja korostaa omaisuuden hallinnan strategista merkitystä organisaatioille. Standardi pyrkii myös auttamaan organisaatioita tunnistamaan ja hyödyntämään omaisuuden hallinnan tarjoamat hyödyt, kuten tehokkaamman resurssien käytön, paremman riskienhallinnan ja suuremman sijoitetun pääoman tuoton.

ISO 55000 määrittelee "omaisuuden" laajasti, sisältäen kaikenlaiset organisaation hallinnoimat resurssit, jotka tuottavat arvoa organisaatiolle. Standardi kattaa seuraavat keskeiset alueet:

- Omaisuu den hallinnan periaatteet
 - Esittelee keskeiset periaatteet, jotka ohjaavat tehokasta omaisuuden hallintaa, kuten arvon luomisen, johtamisjärjestelmän integroinnin ja jatkuvan parantamisen.
- Terminologia
 - Selventää keskeisiä termejä ja määritelmiä, jotka ovat yhteisiä kaikille omaisuuden hallinnan näkökulmille ja aktiviteeteille.
- Omaisuu den hallinnan järjestelmä
 - Kuvaa, kuinka omaisuuden hallintajärjestelmä tulisi rakentaa ja integroida osaksi organisaation muita hallinnollisia toimintoja. Tämä sisältää menettelyt, prosessit ja käytännöt, joita tarvitaan omaisuuden elinkaaren tehokkaaseen hallintaan.

ISO 55000 tarjoaa siis yleisen kehyksen omaisuuden hallinnalle, ja se on suunniteltu olemaan sovellettavissa mihin tahansa organisaatioon, joka pyrkii parantamaan omaisuutensa hallintaa. Standardin käyttöönotto edellyttää kuitenkin sitoutumista ylhäältä alas, mukaan lukien selkeät johtamiskäytännöt ja -prosessit.



Kuvio 5: Käsiteiden väliset suhteet ISO 55000 standardissa (ISO 55000:2014)

4.3.3 ISO 55001

ISO 55001:n tarkoituksena on tarjota selkeät vaatimukset omaisuudenhallintajärjestelmälle, mikä mahdollistaa organisaatioiden omaisuudenhallinnan tavoitteiden saavuttamisen. Nämä tavoitteet liittyvät muun muassa kustannustehokkuuteen ja suorituskyvyn parantamiseen. Tämän standardin avulla organisaatiot voivat optimoida omaisuuden käyttöä ja ylläpitoa koko sen elinjakson ajan.

ISO 55001 sisältää konkreettisia vaatimuksia, jotka koskevat omaisuudenhallintajärjestelmän rakennetta, toimintaa ja ylläpitoa. Näitä vaatimuksia ovat muun muassa:

- Johdon sitoutuminen
 - Standardi korostaa johdon roolia omaisuuden hallinnassa, vaatien selkeää sitoutumista ja näkyvää johtajuutta.
- Suunnittelu
 - Vaatimukset kattavat omaisuuden hallinnan strategisen ja operatiivisen suunnittelun, riskien arvioinnin ja hallintatoimien suunnittelun.
- Tukitoiminnot
 - Ohjeistus koskee myös tarvittavia resursseja, tietoa ja osaamista, jotka ovat välttämättömiä tehokkaalle omaisuuden hallinnalle.
- Toiminta
 - ISO 55001 määrittelee, kuinka omaisuudenhallintatoimia tulee operatiivisesti toteuttaa ja ylläpitää.
- Seuranta ja analysointi
 - Standardi vaatii jatkuvaa suorituskyvyn seuranta ja arviointia, mukaan lukien sisäiset auditoinnit ja säännölliset arviot omaisuuden hallintajärjestelmän tehokkuudesta.
- Parantaminen
 - Jatkuva parantaminen on keskeinen osa ISO 55001:ää ja se vaatii organisaatioita kehittämään omaisuuden hallintaprosessejaan säännöllisesti.

ISO 55001 auttaa siis organisaatioita saavuttamaan suurempaa arvoa omaisuudestaan systemaattisella lähestymistavalla. Sen avulla pyritään vähentämään riskejä, odottamattomia kuluja sekä varmistamaan toiminnan jatkuvuus. ISO 55001 tarjoaa vankan perustan organisaatioille, jotka haluavat parantaa omaisuudenhallintansa laatua ja tehokkuutta. Standardin noudattaminen ei ainoastaan paranna operatiivista tehokkuutta, vaan se myös lisää luottamusta sidosryhmien keskuudessa, mikä on elintärkeää nykypäivän kilpailuympäristössä. (ISO 55001:2014)

4.3.4 ISO 55002

ISO 55002:n tavoitteena on tarjota selkeät ja konkreettiset ohjeet ISO 55001 -standardin vaatimusten toteuttamiseen. Se auttaa organisaatioita kehittämään omaisuuden hallintajärjestelmäänsä tavalla, joka tukee organisaation strategisia tavoitteita ja parantaa sen kykyä hallita omaisuuttaan tehokkaasti. ISO 55002 sisältää useita osa-alueita, jotka ohjaavat organisaatioita omaisuuden hallintajärjestelmän kehittämisessä:

- Soveltamisohjeet
 - Standardi tarjoaa ohjeita siitä, kuinka erilaiset ISO 55001:n elementit voidaan toteuttaa käytännössä. Tämä sisältää esimerkkejä, kuinka standardia voidaan soveltaa eri organisaatioissa, kuten pk-yrityksissä. ISO 55002 esittelee liitteenään oppaita eri toteutuksiin, muun muassa strategisen omaisuudenhallintasuunnitelman tekemiseen ja käyttöön.
- Räättälöinti organisaation tarpeisiin
 - Ohjeistus kattaa myös, kuinka järjestelmää voidaan muokata kunkin organisaation ainutlaatuisiin tarpeisiin ja olosuhteisiin sopivaksi.
- Riskienhallinta
 - Erityistä huomiota kiinnitetään siihen, kuinka riskienhallintaa voidaan integroida osaksi omaisuuden hallintaa, mikä on keskeistä varmistettaessa omaisuuden optimaalinen suorituskyky ja elinkaaren kustannustehokkuus.
- Jatkuvan parantamisen prosessit
 - Standardi painottaa jatkuvan parantamisen merkitystä ja tarjoaa ohjeita siitä, kuinka organisaatiot voivat systemaattisesti arvioida ja parantaa omaisuuden hallintaprosessejaan.

(ISO 55002:2018)

4.3.5 ISO 55010

ISO 55010 on erityisesti suunniteltu ohjaamaan organisaatioita yhdistämään omaisuudenhallinnan tavoitteet laajempiin organisaation tavoitteisiin varmistuen, että omaisuus täyttää jatkuvasti tarkoituksensa tehokkaasti ja kestävästi. ISO 55010 -standardi syventyy omaisuudenhallinnan periaatteisiin, korostaen systemaattista, prosessikeskeistä lähestymistapaa, joka sisältää kustannusten, riskien, mahdollisuuksien ja suorituskyvyn hyötyjen tasapainottamisen. ISO 55010:n soveltaminen ulottuu useille sektoreille mahdollistaen organisaatioille omaisuudenhallintakäytäntöjensä parantamisen, luotettavuuden lisäämisen ja toiminnallisen suorituskyvyn optimoinnin.

ISO 55010:n tarkoitus on auttaa organisaatiota ISO 55000:ssa esiteltyjen käsitteiden soveltamisessa ja ISO 55001:ssä esiteltyjen vaatimusten toteuttamisessa organisaation taloudellisten ja ei-

taloudellisten toimintojen yhdenmukaistamiseen osana tehokkaampaa omaisuudenhallintaa. Taloudelliset toimet kuten kirjanpito, budjetointi, rahoitus ja arvonmääritys ovat keskeisessä osassa organisaation strategiaa tukevassa omaisuudenhallintajärjestelmässä. Määrittelemällä selkeät määritelmät yleisesti käytetyille talous- ja omaisuudenhallinnan termeille sekä asettamalla kehykset tiedonhallinnalle ja suorituskyvyn arvioinnille, ISO 55010 auttaa organisaatioita saavuttamaan kokonaisvaltaisen näkemyksen omaisuuden suorituskyvystä. Tämä yhdenmukaistaminen on ratkaisevan tärkeää, jotta voidaan tehdä tietoon perustuvia, strategisia päätöksiä, jotka optimoivat omaisuuden arvon ja täyttävät laajemmat liiketoiminnalliset tavoitteet. (ISO/TS 55010:2019)

4.3.6 Syyt ISO 55000 -standardin implementointiin

Standardi EN-16646, 2014 listaa seuraavat syyt omaisuudenhallinnan tarpeellisuudelle (EN 16646:2015):

- Globalisaatio ja lisääntynyt kilpailu
- kasvavat taloudelliset, turvallisuus- ja ympäristöriskit
- merkittävä muutos liiketoimintastrategioissa – pitkä jänne vs. lyhyt jänne
- fyysiseen omaisuuden hallintaan kohdistuvat asenteet ovat muuttuneet – nykyään entistä useammin omistuksen pituus ei vastaa kohteen (laitteiston) koko elinikää
- pääomavaltaisuuden lisääntyminen joillakin teollisuuden toimialoilla
- kasvava turbulenssi markkinoilla
- paine parantaa kannattavuutta ja pääoman tuottoastetta
- fyysisten omaisuuskokonaisuuksien ikääntyminen
- lisääntyvä paine parantaa kunnossapidon tuottamaa lisäarvoa
- entistä monimutkaisempi ja epävarmempi päätöksentekoympäristö
- kohonneet turvallisuuteen ja ympäristöön kohdistuvat vaatimukset
- ”siilokäyttäytyminen” organisaatioissa, mikä pitää kunnossapidon ja muut elinjaksoprosessit erillisinä toimintoina.

Vaikka tähän mennessä ISO 55000 -standardi on suurten omaisuserien omistavien yritysten käyttämä, voi moni pienempikin yritys tunnistaa yllä listatut ongelmat. Esimerkiksi kuljetusalalla yrityksen käyttämän kaluston arvo voi pienessä yrityksessä olla alle miljoonan euron, mutta tämä omaisuserä on liiketoiminnalle välttämätön. Suuremmalla kuljetusyrityksellä kaluston arvon kasvaessa, ovat omaisuudenhallintajärjestelmällä tavoitellut hyödytkin suuremmat. Kaiken kaikkien

aan, pienet ja keskisuuret yrityksetkin voivat hyötyä omaisuudenhallinnasta, mikäli heidän omistama ja käyttämä fyysinen omaisuus on heidän liiketoimintansa tehokkuudelle kriittistä. ISO 55002 antaa ohjeita standardin implementointiin pk-yrityksessä.

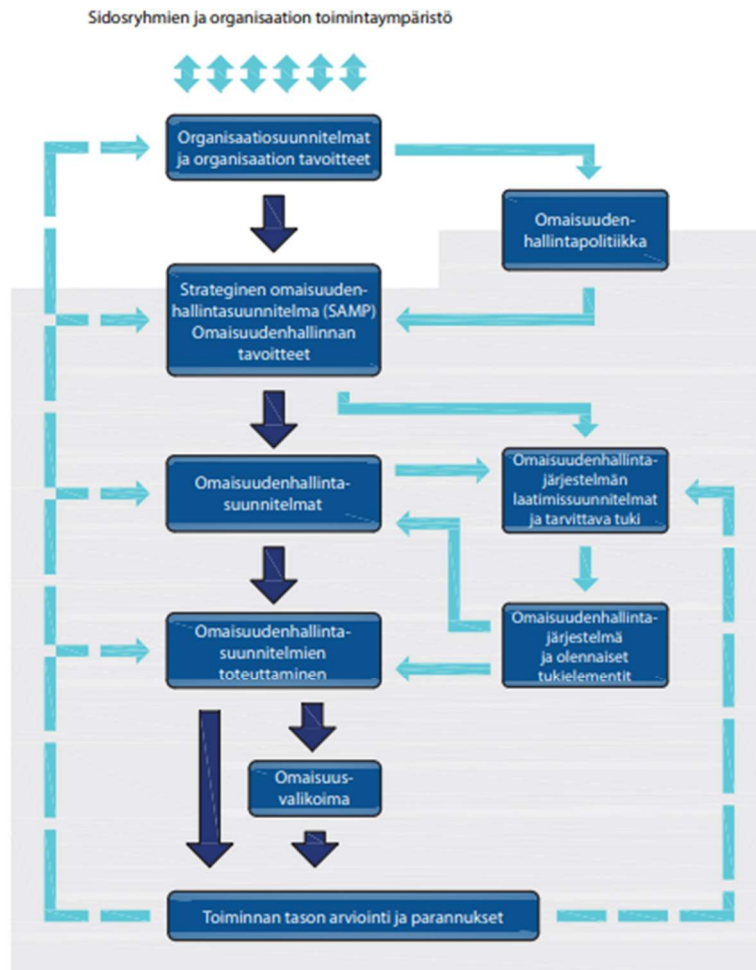
4.4 Omaisuudenhallintajärjestelmä

Hyvä omaisuudenhallintaprosessi on sellainen, joka sovittaa organisaation omaisuudenhallinnan tavoitteet yhteen sen yleisten liiketoimintatavoitteiden kanssa samalla kun optimoidaan omaisuuden suorituskykyä, minimoidaan riskejä ja maksimoidaan arvo. Toimivaan strategiseen omaisuuden hallintaprosessiin kuuluvat keskeiset elementit:

- Omaisuuden hallinnan tavoitteiden yhteensovittaminen organisaation tavoitteiden kanssa:
 - Selkeä ymmärrys organisaation missiosta, visiosta ja strategisista tavoitteista
 - Omaisuuden hallinnan strategiat, jotka tukevat ja mahdollistavat näiden tavoitteiden saavuttamisen
 - Säännöllinen omaisuuden hallintasuunnitelmien tarkastelu ja säätäminen jatkuvan yhteensopivuuden varmistamiseksi
- Kattava omaisuustietojen ja -tiedon hallinta:
 - Tarkka ja ajan tasalla oleva inventaario kaikista omaisuuseristä, mukaan lukien niiden ominaisuudet, kunto ja suorituskykytiedot
 - Omaisuustiedon integrointi eri lähteistä keskitettyyn omaisuusrekisteriin
- Tehokkaat tiedonhallinnan ja laadunhallinnan prosessit
 - Omaisuuteen liittyvien riskien tunnistaminen, arviointi ja priorisointi, esimerkiksi vikaantuminen, vanhentuminen, vaatimuksenmukaisuus
 - Riskien mitigointistrategioiden ja hätäsuunnitelmien kehittäminen
 - Riskiprofiilien ja käsittelyn tehokkuuden säännöllinen seuranta ja tarkastelu
- Elinkaaren hallinta:
 - Huomio omaisuuden koko elinkaareen, suunnittelusta ja hankinnasta käyttöön, ylläpitoon ja hävittämiseen
 - Omaisuuden suorituskyvyn ja kustannusten optimointi elinkaaren aikana
 - Tehokas suunnittelu ja budjetointi omaisuuden korvaamiseen ja uusimiseen
- Suorituskyvyn seuranta ja jatkuva parantaminen:
 - Keskeisten suorituskykymittareiden määrittely omaisuuden ja omaisuuden hallinnan prosessien osalta
 - Omaisuuden suorituskyvyn säännöllinen mittaus, analysointi ja raportointi
 - Parannusmahdollisuuksien tunnistaminen ja korjaavien toimenpiteiden toteuttaminen
 - Vertailu alan parhaisiin käytäntöihin ja standardeihin
- Sidosryhmien osallistuminen ja viestintä:

- Keskeisten sidosryhmien, esimerkiksi työntekijät, asiakkaat, sääntelyviranomaiset, sijoittajat, tunnistaminen ja heidän vaatimustensa ymmärtäminen
- Säännöllinen neuvottelu ja viestintä sidosryhmien kanssa heidän tarpeidensa ja odotustensa ymmärtämiseksi
- Avoin raportointi omaisuuden hallinnan suorituskyvystä ja aloitteista
- Pätevä ja valtuutettu työvoima:
 - Selkeä roolien, vastuiden ja osaamisvaatimusten määrittely omaisuuden hallinnan henkilöstölle
 - Riittävän koulutuksen, työkalujen ja resurssien tarjoaminen tehokkaan omaisuuden hallinnan mahdollistamiseksi
 - Vastuullisuuden, yhteistyön ja jatkuvan oppimisen kulttuurin edistäminen
- Integrointi muiden liiketoimintaprosessien kanssa:
 - Omaisuuden hallinnan yhteensovittaminen muiden keskeisten prosessien kanssa (esim. talous, hankinta, riskienhallinta, turvallisuus)
 - Poikkitieteellinen yhteistyö ja tiedon jakaminen
 - Integroitu suunnittelu ja päätöksenteko organisaatiossa
- Hallinto ja johtajuus
 - Selkeä omaisuuden hallinnan politiikka, strategia ja tavoitteet ylimmän johdon hyväksymänä
 - Määritelty hallintorakenne rooleineen ja vastuineen omaisuuden hallinnan päätöksenteon osalta
 - Säännöllinen johtamisen tarkastelu ja valvonta omaisuuden hallinnan suorituskyvystä ja parannusaloitteista

(ISO 55000:2014; PAS 55-1 2008)



HUOM. Harmaa laatikko kuvaa omaisuudenhallintajärjestelmän rajoja.

Kuvio 6: Omaisuudenhallintajärjestelmä ISO 55000 -standardin mukaan (ISO 55000:2014, 42)

4.5 Tehokkaan omaisuudenhallinnan hyödyt

IAM nostaa teoksessaan *An Anatomy of Asset Management* esimerkeiksi omaisuuden hallinnan hyödyksi seuraavat:

- Parantunut taloudellinen suorituskyky
- Perustellut investointipäätökset
- Hallittu riski
- Parannetut palvelut ja tuotteet
- Osoitettu yhteiskuntavastuu
- Osoitettu määräysten noudattaminen
- Parantunut maine
- Parantunut organisaation kestävyys
- Parantunut tehokkuus ja tuottavuus

(Asset Management - An Anatomy 2015)

Noudattamalla ISO 55000 -standardeja yritykset voivat parantaa omaisuuseriensä suorituskykyä, tehokkuutta ja luotettavuutta. Tämä varmistaa, että jokaista omaisuuserää käytetään sen maksimaaliseen potentiaaliin samalla kun operatiiviset kustannukset minimoidaan. ISO 55000:n mukainen omaisuudenhallintajärjestelmä auttaa tunnistamaan ja hallitsemaan omaisuuden hallintaan liittyviä riskejä, kuten odottamattomia hajoamisia, turvallisuuspoikkeamia ja vaatimustenmukaisuusongelmia. Tämä ennakoiva lähestymistapa riskienhallintaan tukee liiketoiminnan jatkuvuutta ja vähentää mahdollisia tappioita.

Standardi kannustaa dataan perustuvaan päätöksentekoon, mikä mahdollistaa organisaatioille resurssien tehokkaamman kohdentamisen. Tämä sisältää perusteltuja päätöksiä ajoneuvojen huollosta, korvaamisista ja hankinnoista. ISO 55000 -standardien käyttöönotto auttaa organisaatioita ymmärtämään ja hallitsemaan kalustonsa kokonaiskustannuksia. Tämä kattaa hankinta-, käyttö-, huolto- ja hävittämiskustannukset, auttaen minimoimaan omaisuuden elinjakson kustannukset.

Sitoutuminen kansainvälisesti tunnustettuihin omaisuudenhallintastandardeihin voi myös parantaa organisaation mainetta sidosryhmien, kuten asiakkaiden, sijoittajien ja sääntelyviranomaisten keskuudessa. Tämä on erityisen merkittävää yrityksille, joilla on merkittävä ja pitkäikäinen omaisuus hallittavanaan, kuten vesi-, sähkö- ja liikenneinfran omistajat. ISO 55000 -standardien noudattaminen voi auttaa varmistamaan, että hallintakäytännöt täyttävät asiaankuuluvat lain ja sääntelyn vaatimukset, vähentäen ei-vaatimustenmukaisuuden seuraamusten riskiä.

5 Elinjakso ja sen vaiheet

Ajoneuvon tai laitteen elinjakso kattaa useita vaiheita suunnittelusta ja valmistuksesta aina sen lopulliseen poistamiseen käytöstä. Näiden vaiheiden ymmärtäminen auttaa optimoimaan sen suorituskykyä, huoltoa ja ympäristövaikutuksia koko sen toiminta-ajan. Geneerisen elinjaksomallin mukaan laite käy läpi kuusi eri vaihetta elinjaksonsa aikana (Kuvio 7):

- Suunnittelu ja Kehitys

- Tässä alkuvaiheessa keskitytään laitteen käsitteellistämiseen ja suunnitteluun. Suunnittelijat ottavat huomioon tekijöitä, kuten tarkoitetun käytön, kestävyuden, polttoainetehokkuuden, päästöt ja sääntelyn noudattamisen.
- Toteutus
 - Suunnitelman valmistuttua valmistusvaihe käsittää osien tuotannon ja laitteen kokoonpanon. Tämä vaihe vaatii koordinoitua eri toimittajien kanssa ja laadunvalvontastandardien noudattamista varmistaakseen, että kaikki osat täyttävät vaaditut määrittelyt.
- Käyttö ja Huolto
 - Laitteen elinkaaren laajin vaihe on sen käyttöaika. Tänä aikana laitetta käytetään aktiivisesti, ja säännöllinen huolto on välttämätöntä sen luotettavuuden, turvallisuuden ja tehokkuuden varmistamiseksi. Huoltoaikataulu riippuu usein laitteen käytön laajuudesta, toimintaympäristöstä ja iästä.
- Parantaminen
 - Tässä elinjakson vaiheessa laitteelle tehdään peruskorjauksia ja parannuksia, jotta sen kyvykkyys vastaa sille asetettuja tavoitteita vielä käytöstä poistoon saakka.
- Käytöstä poisto tai uusiokäyttö
 - Lopulta, kun laite saavuttaa käyttöikänsä lopun, se siirtyy eläköitymisvaiheeseen. Tämä saattaa johtua mekaanisesta viasta, taloudellisesta vanhentumisesta tai liiallisesta kulumisesta. Vastuulliset hävittämiskäytännöt ovat tärkeitä ympäristövaikutusten minimoimiseksi. Joissakin tapauksissa poistuneiden laitteiden osia voidaan kunnostaa tai kierrättää. Hyväkuntoiset komponentit voivat toimia varaosina muissa ajoneuvoissa, mikä edistää resurssien säästämistä ja jätteen vähentämistä.



Kuvio 7: Geneerinen elinjaksomalli ((IEC 60300-1 2014) kuten ilmaistu teoksessa Tietämysperusteinen Elinjaksonhallinta (Kortelainen ym. 2021))

Hastings jakaa vaiheet omistajan näkökulmasta siten, että laitteen elinjakso alkaa tarpeen tunnistamisesta (Kuvio 8). Laitteen ostaja harvoin voi ottaa kantaa laitteen suunnitteluun, mikäli puhutaan tuotteista kuten kuorma-auto, jota tilaaja voi muuttaa niiltä osin, mitä valmistaja sallii, mutta ei sen enempää.



Kuvio 8: Elinjakson vaiheet omistajan näkökulmasta (Hastings 2010)

Kuorma-auton omistajan kannalta merkittävien elinjakson vaihe ovat käyttö, jonka aikana ajoneuvo kerää hyvin usein suurimman osan kustannuksistaan. Käyttövaihe voidaan vielä erikseen jakaa osiin, kuten alkuvaiheen sisäänajo, täysi toimintajakso, keskivaiheen peruskorjaus ja kunnan heikkeneminen.

Kun kuorma-auto on uusi, se käy läpi sisäänajokauden, jossa moottori, vaihteisto ja muut komponentit sopeutuvat asteittain käyttörasitukseen. Ylläpito tässä vaiheessa on ratkaisevan tärkeää pitkäikäisyyden ja optimaalisen suorituskyvyn varmistamiseksi. Valmistajan määrittämien sisäänajomenettelyjen noudattaminen on tässä vaiheessa tärkeää, kuten myös huolto-ohjelman noudattaminen.

Sisäänajokauden jälkeen kuorma-auto siirtyy pääasialliseen toimintavaiheeseensa. Tämä on tyypillisesti ajoneuvon pisin vaihe, jossa se toimii tehokkaasti. Huolto on rutiininomaista, mutta kriittistä tämän suorituskyvyn ylläpitämiseksi. Tämän vaiheen aikana ajoneuvolle tehdään lähinnä säännöllisiä rutiininomaisia huoltoja. Kuorma-auton vanhetessa ja merkittävän kilometrimäärän kertyessä, se voi käydä läpi keskivaiheen peruskorjauksen, mikäli se koetaan taloudellisesti järkeväksi. Tässä vaiheessa voidaan investoida joidenkin kuorma-auton osien kunnan palauttamiseen varmistaen jatkuvan luotettavuuden ja tehokkuuden.

Kuorma-auto saattaa viimeisinä toimintavuosinaan vaatia intensiivisempää huoltoa, kun komponentit kuluvat ja vikojen riski kasvaa. Huoltokustannukset voivat nousta merkittävästi ja toiminnallinen tehokkuus saattaa heiketä. Tässä elinjakson vaiheessa ajoneuvon kustannuksista merkittävä osa on reaktiivista kunnossapitoa, eli vian korjausta. Jossain kohtaa ajoneuvon kustannukset kasvavat ja käytettävyys heikkenee siihen pisteeseen, että ajoneuvo on korvattava.

6 Kaluston korvaus ja kustannusennuste osana omaisuudenhallintaa

6.1 Kaluston korvaamisella tavoitellut hyödyt

Laitteen oikea-aikainen korvaaminen liittyy olennaisesti fyysisen omaisuuden hallintaan ISO 55000 -standardin yhteydessä. Kun organisaatioilla on fyysistä omaisuutta, kuten laitteita tai koneita, niiden on tärkeää hallita näiden varojen elinkaarta tehokkaasti. Oikea-aikainen korvaaminen tarkoittaa sitä, että organisaation tulisi pystyä arvioimaan, milloin fyysinen omaisuus on saavuttanut sen käyttöikänsä loppuun, ja päättämään, onko sen korvaaminen uudella laitteella kannattavaa. (Hastings 2010; ISO 55000:2014)

Tämä päätös perustuu usein erilaisiin tekijöihin, kuten laitteen nykyiseen kuntoon, sen ylläpitokustannuksiin, teknologisen kehityksen vaikutukseen, riskianalyysiin ja organisaation strategiaan tavoitteisiin. Oikea-aikainen korvaaminen voi auttaa organisaatiota välttämään suuret korjauskustannukset, vähentämään toimintakatkot ja parantamaan toiminnan tehokkuutta. Hastings jakaa kaluston korvauksen syyt kolmeen osa-alueeseen: Tekniset, kaupalliset ja säätelyyn liittyvät syyt (2010, s.211-2012). Monesti on otettava huomioon useita, ellei kaikki osa-alueet korvaussuunnitelmaa tehdessä, mikäli esimerkiksi kaluston elinjakso on kymmenen vuotta, voi sinä aikana asiakkaiden vaatimukset polttoaineen suhteen muuttua siten, ettei nyt ostettava kalusto ole enää kurranttia. Samoin muutokset säätelyn osalta, esimerkiksi polttoaineen verotuksen suhteen tai polttomoottorien kieltäminen tietyillä alueilla, saattavat olla asioita, joita on otettava huomioon jo nyt.

Yhteenvedona ISO 55000 -standardi kannustaa organisaatioita ottamaan kokonaisvaltaisen lähestymistavan fyysisen omaisuuden hallintaan, joka sisältää strategisen suunnittelun, toimeenpanon ja jatkuvan seurannan. Oikea-aikainen korvaaminen on osa tätä prosessia, joka auttaa varmistamaan, että organisaatio optimoi fyysisen omaisuuden arvon ja suorituskyvyn pitkällä aikavälillä.

6.2 Korvaus-ajankohta

Optimaalisen ajankohdan löytämiseen laitteen korvaamiseksi voidaan käyttää useita eri menetelmiä. Näitä ovat esimerkiksi eri optimointitekniikat, minimi EAC-lähestymistapa (EAC, Equivalent


Annual Cost) ja kustannusanalyysit, jotka auttavat määrittämään, mikä on paras korvausvaihtoehto. Myös teknisten ja taloudellisten tutkimusten tekeminen voi olla hyödyllistä, kun valitaan optimaalinen korvaussuunnitelma.

David Wilson kirjoittaa kirjassaan *The Ultimate Guide to Commercial Vehicle Fleet Management*, että useat kaluston omistajat eivät laske optimaalista vaihtoajankohtaa kalustolleen, vaan luottavat ennalta määrättyihin rajoihin, jotka perustuvat esimerkiksi kilometrisuoritteeseen tai ikään. Wilsonin mukaan yritykset ovat monesti päätyneet tähän toimintatapaan syystä tai toisesta, eikä sen toimintaa enää osata kyseenalaistaa. (Wilson 2021). Kyseisellä toimintatavalla yritykseltä jää hyödyntämättä suuri määrä heidän käytettävissään olevaa dataa ja saavuttaa kilpailukykyä tehokkaammalla kalustolla. Oikea-aikaisella kaluston korvaamisella ei pelkästään saada säästöjä kunnossapitokustannuksista, vaan myös liiketoiminnallista hyötyä tehokkaammalla toiminnalla. Markkinoilla voi korvaushetkellä olla tarjolla esimerkiksi polttoainetehokkaampi, tai muuten tarkoitukseen sopivampi laite. Korvaamalla kalustoa ennalta määrättyjen raja-arvojen perusteella, ei myöskään oteta huomioon muuttuvaa maailmantilannetta, uusia teknologioita tai ajoneuvoyksilökohtaisia eroja. Wilson nostaa esiin myös ympäristönäkökulman kaluston korvaamisessa - korvaussuunnitelmassa on otettava huomioon yrityksen päästötavoitteet (Wilson 2021). Nämä tavoitteet vaikuttavat hankittavan kaluston voimanlähteeseen ja käytettävään teknologiaan. Vaikka päästötavoitteet eivät vaatisikaan dieselpolttoaineesta luopumista siinä aikataulussa, missä korvauspäätöksen kohteena olevat ajoneuvot ovat poistumassa, kehitty myös polttomoottoriajoneuvot ja niiden hyötysuhde koko ajan. Volvo Trucks kertoo sivuillaan, että vuonna 2022 julkaistu I-Save on testeissä vähentänyt polttoaineenkulutusta jopa 18 % verrattuna neljä vuotta aikaisempaan tulokseen. Kyseinen parannus on saatu moottoritekniikan kehittämisen lisäksi aerodynaamiikkaa parantamalla, sekä ohjelmistoja kehittämällä. (Volvo Trucks cuts fuel use by 18% in road test 2022)

Wilson listaa kaluston vaihdon laukaiseviksi tekijöiksi iän tai matkamittarilukeman, koko eliniän kustannusten analyysin (Whole life cost analysis) ja kustannusraja-arvoanalyysi. (Cost threshold analysis). Tärkeimmiksi mittareiksi Wilson määrittelee kilometrisuoritteen, ajoneuvon iän ja kustannukset per kilometri. (Wilson, 2021). Tässä työssä pyritään koko eliniän kustannusten ennustamiseen. Kyseisellä menetelmällä pyritään ottamaan huomioon kaikki ajoneuvon kustannukset kuten hankintakustannukset, arvonaleneminen, kunnossapitokustannukset ja vauriot, sekä

polttoainekustannukset. Myös ajoneuvon vikaantumisista johtuvan seisonta-ajan laskennallinen kustannus otetaan tässä työssä huomioon kokonaiskustannuksissa. Kustannus per kilometri on hyvä indikaattori myös seisonta-ajasta, mikäli sitä ei kyetä seuraamaan muilla keinoin. Mikäli ajoneuvo on korjattavana usein, sen kustannukset totta kai nousevat, mutta korjaamalla vietetyn ajan takia sen kilometrit laskevat, jolloin kustannus per kilometri nousee rajusti.


Wilson määrittelee kustannusraja-arvoanalyysin siten, että kalusto vaihdetaan kun sen kunnossapitokustannukset ylittävät jonkin tietyn osuuden, kuten 30 %, kaluston arvioidusta jäännösarvosta (Wilson 2021). Tämä menetelmä on edellistä yksinkertaisempi, mutta vaatii silti kustannusten seuranta, sekä säännöllisesti päivitettävän arvion jäännösarvosta. Menetelmä toimii paremmin, mikäli korvattava tuote on yleisesti saatavilla oleva standardituote. Mikäli kyseessä on harvinainen tai poikkeuksellisen pitkän eliniän omaava tuote, voi sen jäännösarvon arviointi olla vaikeaa. Pitkän eliniän omaavan tuotteen kirjanpitoarvo voi olla nolla euroa, vaikka laitteella on käyttöarvoa vielä pitkään. Erikoisen tuotteen myyminen taas voi olla hankalaa, mikäli markkinatilanne on huono. Tällöin sen jäännösarvokin on alhainen jo melko varhaisessa elinkaaren vaiheessa.



Kuvio 9: Korvausanalyysi - tasaisesti nousevat kustannukset (Hastings 2010)

Hastings kuvaa kirjassaan Physical Asset Management esimerkkiä, jossa korvattavan laitteen kustannukset nousevat tasaisesti. Esimerkin kuvaaja (Kuvio 9) havainnollistaa miksi oikea aikainen korvaaminen on tärkeää. Kun esimerkkilaitteen vuosittaiset kustannukset nousevat yli uuden vastaavan laitteen vuosittaisen laskennallisen kustannuksen, eli sen EAC:n, on laitteen optimaalinen

korvausajankohta jo ohitettu, varsinkin jos uuden laitteen toimitusaika on pitkä. Sama lähestymistapa pätee esimerkkiin, missä laitteen kustannukset eivät nouse tasaisesti (Kuvio 14). (Hastings 2010).



Kuvio 10: Epätasaisesti nousevat kustannukset (Hastings 2010)

Equivalent Annual Cost (EAC) on termi, jota käytetään arvioimaan eri investointivaihtoehtojen omistamisen, operoinnin ja kunnossapidon kustannuksia pitkällä aikavälillä ja se lasketaan jakaen investoinnin nettonykyarvo (NNA) jaettuna annuiteettikertoimella. EAC on siis kiinteä vuosittainen summa, jonka nettonykyarvo annetulla ajanjaksolla on sama, kuin laitteen investoinnin, sekä operointi- ja kunnossapitokustannusten nettonykyarvo samalla ajanjaksolla. Tämä menetelmä auttaa vertailemaan investointien kustannustehokkuutta, erityisesti kun investoinnit kestävät eri pituisia aikoja tai niiden käyttöikä ja ylläpitokustannukset vaihtelevat. EAC:llä voidaan siis arvioida, mikä investointi tarjoaa parhaan taloudellisen hyödyn suhteessa sen elinjakson arvioituihin kustannuksiin. EAC:llä saadaan arvoitu vuosittainen kokonaiskustannus laitteelle, ottaen huomioon sen hankintahinta, operointi- ja kunnossapitokustannukset, sekä mahdolliset hävittämisestä koituvat kulut.

$$NNA = \sum_{t=0}^n \frac{Rt}{(1+r)^n}$$

$$\text{Annuiteettikerroin} = \frac{1 - \frac{1}{(1+r)^n}}{r}$$

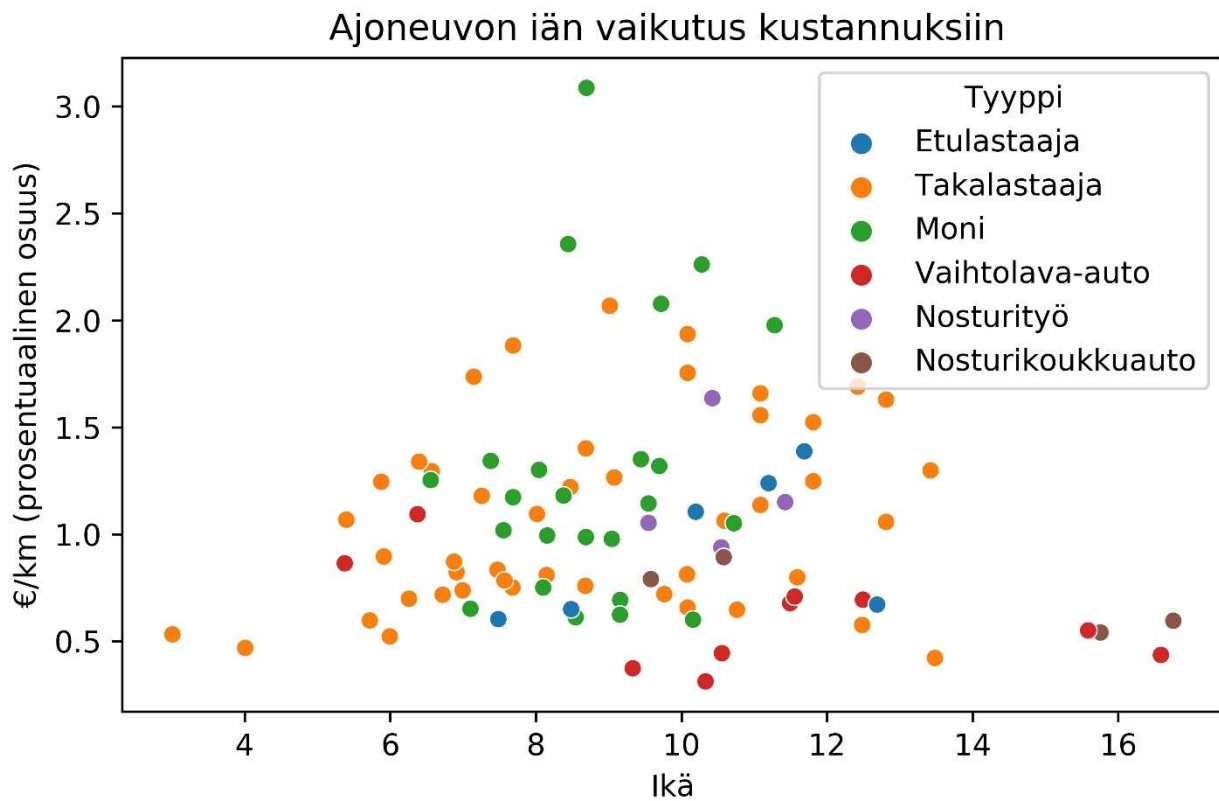
$$EAC = \frac{NNA}{\text{Annuiteettikerroin}}$$

(Hastings 2010)

Missä n on periodien lukumäärä, r on diskonttokorko ja R on kustannukset ajanjaksolla t .

Eri optimointimallit, kuten Deterministic Dynamic Programming ja sen jatke Stochastic Dynamic Programming ovat eräitä malleja, joita on käytetty optimaalisen korvausajankohdan löytämiseen (Fan, Machemehl & Kortum 2011). Mikäli korvausajankohta määräytyy ainoastaan lineaarisesti kehittyvien kustannusten perusteella, on ongelma ratkaistavissa lineaarioptimoinnin keinoin. Kuitenkin kuorma-autojen tapauksessa pelkät kokonaiskustannukset eivät ole riittävä kohde, eikä ne välttämättä kasva lineaarisesti käytön tai iän mukaan. Kuvio 3 ilmaisi kuinka ajoneuvon kilometrisuorite laskee sen ikääntymisen myötä, kun taas Kuvio 11 näyttää €/km kustannusten kehityksen ajoneuvon ikääntymisen myötä. Ajoneuvon ajosuoritteen laskettua myös €/km -kustannukset nousevat, koska usein ajoneuvon korjaamalla viettämä aika kasvaa korjauskustannusten myötä, ja täten kilometrit pienenevät. Kuitenkin, mikäli ajoneuvo vanhenee vielä yli tämän vaiheen, saattavat ajoneuvon ajamat kilometrit pudota niin pieniksi, ettei myöskään kunnossapitokustannuksia pääse kertymään. Näin voi tapahtua esimerkiksi erikoisajoneuvojen kanssa, joiden vuosittainen kilometrisuorite jää muutenkin pieneksi.

Remeo Groupin tapauksessa oli selvää, että optimaalinen korvausajankohta on jo useiden ajoneuvojen osalta mennyt. Yrityksellä oli siis investointivelkaa ja optimaalisen korvausajankohdan sijaan keskityttiin tehokkaimpaan mahdolliseen korvaussuunnitelmaan, jolla pyrittiin kuromaan kiinni investointivelasta johtuvaa tehokkuusvajetta. Tällaisessa tapauksessa korvaussuunnitelmassa on otetta huomioon eri ajoneuvojen erilaiset roolit, ja pyrittävä hyödyntämään ajoneuvoja vielä niiden nykyisen roolinsa ulkopuolella. Esimerkiksi kahdeksanvuotias ajoneuvo, joka on ajanut kahdessa vuorossa koko elinjaksonsa, on hyvin todennäköisesti taloudellisesti kannattavaa korvata, mutta myynnin tai romutuksen sijaan se voidaan mahdollisuuksien mukaan siirtää kevyempiin tehtäviin, korvaamaan vielä huonompikuntoinen ajoneuvo.



Kuvio 11: Ajoneuvon iän vaikutus kustannuksiin

7 Mallit kustannusten arviointiin

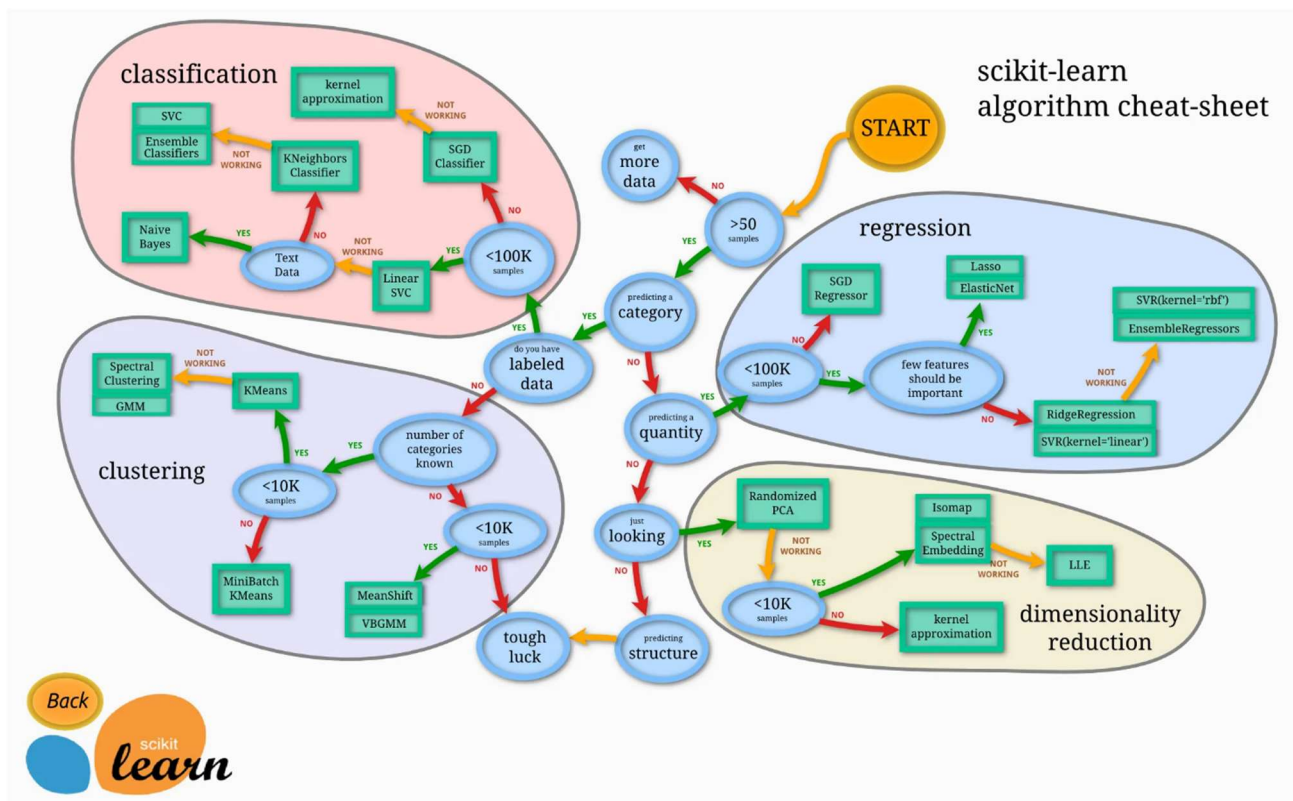
7.1 Koneoppimismallit

Koneoppimismallit ovat tyypillisesti jaettu ohjattuihin (supervised learning) ja ohjaamattomiin (unsupervised learning) oppimismalleihin. Ohjatut oppimismallit ovat jaettu tyypillisesti kahteen osaan:

1. Regressiomallit (Regression model)
2. Luokittelumallit (Classification model)

Regressiomalleilla pyritään ennustamaan tulosta, joka on riippuvainen yhdestä tai useasta muuttujasta. Luokittelumallit taas pyrkivät jakamaan ennalta jaoteltujen malliesimerkkien pohjalta, mihin kahteen tai useampaan luokkaan tuntemattomat esimerkit sopivat.

Siinä missä ohjattu oppiminen käyttää hyödykseen jo tunnettuja muuttujia ja tuloksia, ohjaamaton oppiminen pyrkii tuottamaan mallin ilman tiedettyjä tuloksia. Näitä malleja voidaan käyttää esimerkiksi etsimään ryhmiä annetusta datasta. ("An introduction to machine learning with scikit-learn," 2023). Koska työssä ennustetaan kustannusta, eli summaa, tulevaisuuteen aikaisemman datan perusteella, valitaan käytettäväksi regressiomalli.



Kuvio 12: "SKLearn cheat sheet" https://scikit-learn.org/stable/tutorial/machine_learning_map/index.html

7.2 Regressiomallit

Tässä työssä pyritään ennustamaan kunnossapitokustannusta (tulos), käyttäen hyväksi ajoneuvon tietoja, kuten ikä ja ajetut kilometrit (muuttujat). Tällöin ennustamiseen on käytettävä regressiomallia. Dataa on saatavilla vain muutamia satoja rivejä, joten SKLearn Cheat Sheetin (Kuvio 12) mukaan Lasso, ElasticNet, RidgeRegression, SVR ja EnsembleRegressors -algoritmit olisivat SKLearn-kirjaston malleista sopivimpia tähän tarkoitukseen.

7.2.1 Support Vector Regression (SVR)

Support Vector Regression (SVR) on support vector machine (SVM) -menetelmän sovellus, joka voi käyttää useita "kerneleitä" jotka määrittävät sen toiminnan. Esimerkiksi 'linear'-kernelillä käytettäessä se toimii vastaavasti kuin lineaariregressiomalli (Sethi 2020). Sen perusidea on samankaltainen kuin SVM-luokittelussa: löytää päätösfunktio, joka parhaiten erottaa eri luokat toisistaan, mutta SVR:n tapauksessa tavoitteena on ennustaa jatkuva-arvoista muuttujaa mahdollisimman tarkasti. SVR pyrkii löytämään funktion, joka ennustaa riippuvan muuttujan arvon tarkasti rajatun virhemarginaalin sisällä. Mallin keskeinen idea on luoda niin sanottu "katu", jonka sisällä ennusteet sallitaan poiketa todellisista arvoista ilman rangaistusta. "Katua" ympäröi kaksi marginaalia, jotka määrittävät, kuinka paljon ennusteet voivat poiketa ilman seuraamuksia. (Bennet & Campbell 2000)

Oletusarvoisesti SVR mallintaa lineaarisen yhteyden ominaisuuksien ja ennustettavan muuttujan välillä. Lineaarista SVR-mallia käytetään, kun data oletetaan lineaarisesti eroteltavaksi. Kun suhde selittävien muuttujien ja selitettävän muuttujan välillä ei ole lineaarinen, voidaan käyttää eri kerneliä. Kerneli mahdollistaa SVR-mallin sopeutumisen monimutkaisempiin suhteisiin muuntamalla alkuperäiset data-avaruuden pisteet korkeamman ulottuvuuden tilaan, jossa lineaarinen erotus on mahdollista. Yleisesti käytetyt kernelit ovat polynomikerneli ja Radial Basis Function (RBF). SVR:n yksi keskeinen parametri on epsilon, joka määrittelee, kuinka suuri virhe on sallittu ilman rangaistusta ennusteiden ja todellisten arvojen välillä. (Sharp 2023; Drucker, Burges, Kaufman, Smola & Vapnik 1996).

7.2.2 EnsembleRegressors

EnsembleRegressors viittaa algoritmeihin, kuten Random Forest ja Gradient Boosted Trees, jotka yhdistävät useiden ennusteiden malleja luodakseen yhden robustin mallin. Ensemble-menetelmät scikit-learn-kirjastossa ovat koneoppimisen alueella käytettyjä tekniikoita, jotka pyrkivät parantamaan mallien ennustetarkkuutta ja vähentämään ylisovittamista yhdistämällä useampia yksinkertaisempia malleja monimutkaisemmiksi kokonaisuuksiksi. (1.11. Ensembles: Gradient boosting, random forests, bagging, voting, stacking n.d.)

Random Forest on yksi suosituimmista ensemble-menetelmistä, joka koostuu useista päätöspuista. Se toimii rakentamalla kullakin iteraatiolla uuden puun, joka käyttää satunnaisesti valittua osaa datasta ja ominaisuuksista. Tämä satunnaisuus auttaa vähentämään mallin ylisovittamista ja lisäämään sen yleistettävyyttä. Random Forestin etu on sen kyky käsitellä suuria datamääriä ja monimutkaisia piirteiden suhteita ilman, että mallin suorituskyky heikkenee merkittävästi. (Building a Random Forest Model: A Step-by-Step Guide 2024)

Toinen tehokas ensemble-menetelmä on Gradient Boosting, joka rakentaa mallia lisäämällä järjestelmällisesti uusia malleja, jotka korjaavat edellisten mallien virheitä. Tämä tapahtuu soveltamalla gradienttilaskentaa tappiofunktion minimoimiseksi. Gradient Boosting on erityisen tehokas, kun on kyse ennustetarkkuuden maksimoinnista, ja se soveltuu hyvin sekä regressio- että luokitteluongelmiin. Menetelmän haasteena on sen alttius ylisovittamiselle, erityisesti jos dataa ei ole riittävästi tai siinä on kohinaa. (Gradient Boosting: A Step-by-Step Guide 2024)

Stacking yhdistää useita erilaisia ennustemalleja yhdeksi kokonaisuudeksi. Tässä menetelmässä eri mallit, metamallit, tuottavat ennusteita, jotka toimivat syötteenä toiselle mallille. Meta-malli oppii, kuinka yhdistää yksittäisten mallien ennusteet parhaalla mahdollisella tavalla saavuttaakseen paremman ennustetarkkuuden. Stacking on monipuolinen tekniikka, joka mahdollistaa monenlaiset malliyhdistelmät ja on tehokas erityisesti silloin, kun eri mallit tuottavat hyvin erilaisia ennusteita. (Stacking Algorithms in Machine Learning - Analytics Vidhya 2022)

Näiden menetelmien avulla voidaan rakentaa robustimpia ja tarkempia malleja, jotka ovat välttämättömiä monimutkaisten datan mallintamisongelmien ratkaisemiseksi nykyaikaisessa koneoppimisessa. Ne ovat tärkeä osa scikit-learn -kirjaston tarjontaa ja tarjoavat käyttäjille monipuolisia työkaluja datan analysointiin ja ennustamiseen. (1.11. Ensembles: Gradient boosting, random forests, bagging, voting, stacking n.d.)

7.2.3 Ridge, Lasso ja ElasticNet

Lasso, ElasticNet ja Ridge Regression ovat regressioanalyysin menetelmiä, jotka kuuluvat säännöllistettyjen regressiomallien perheeseen. Ne on suunniteltu estämään ylisovitus ja parantamaan mallien yleistettävyyttä, erityisesti tilanteissa, joissa selittäviä muuttujia on paljon suhteessa ha-

vaintojen määrään. (Ansari 2023). Lasso, ElasticNet ja RidgeRegression ovat keskenään hyvin samankaltaisia algoritmejä ja ovat kaikki toiminnaltaan lineaariregressiomalleja. Ne eroavat toisistaan niiden tavoilla käsitellä muuttujien painoarvoja (Maklin 2018)

Least Absolute Shrinkage and Selection Operator, eli Lasso käyttää L1-säännöllistämistä, mikä tarkoittaa, että se rankaisee mallin kertoimien absoluuttisten arvojen summaa. Tämä johtaa siihen, että vähemmän tärkeiden muuttujien kertoimet kutistuvat nolliin, mikä auttaa muuttujien valinnassa ja tuottaa harvemman mallin. Lasso on hyödyllinen, kun datassa on monia muuttujia ja oletetaan, että vain osa niistä on merkityksellisiä selittäviä tekijöitä. (Maklin 2018)

Ridge-regressio käyttää L2-säännöllistämistä, joka rankaisee kertoimien neliöiden summaa. Tämä menetelmä ei tyypillisesti saa aikaan nollakertoimia, mutta se pienentää kertoimia tasaisesti, mikä auttaa vähentämään mallin kompleksisuutta ja estämään ylisovitusta. Ridge on erityisen hyödyllinen tilanteissa, joissa selittäviä muuttujia on paljon ja ne ovat keskenään korreloituneita.

(sklearn.linear_model.Ridge n.d.)

ElasticNet yhdistää Lasso- ja Ridge-regression ominaisuudet käyttämällä sekä L1- että L2-säännöllistämistä. Tämä menetelmä on hyödyllinen, kun datassa on useita korreloituneita muuttujia ja kun halutaan yhdistää Lasso-menetelmän muuttujavalinnan etuja ja Ridge-menetelmän kykyä käsitellä korrelaatioita. ElasticNet voi tarjota paremman mallin suorituskyvyn, kun sekä L1- että L2-säännöllistäminen ovat tarpeen. (Dhumne 2023)

Nämä menetelmät ovat tärkeitä työkaluja, koska ne tarjoavat joustavuutta ja robustisuutta mallien rakentamisessa. Ne auttavat erityisesti tilanteissa, joissa perinteiset mallit, kuten tavallinen pienimmän neliösumman menetelmä, voivat johtaa ylisovitukseen tai ovat tehottomia korkean dimensionaalisuuden vuoksi.

7.3 Python ja SKLearn

Python on korkean tason ohjelmointikieli, joka on suunniteltu yksinkertaisuutta ja selkeyttä silmällä pitäen. Sen kehitti Guido van Rossumin vuonna 1991 ja sen kehitys jatkuu edelleen aktiivisesti ympäri maailmaa. Pythonilla on laaja käyttöalue, ja se sopii erityisen hyvin web-kehitykseen, tieteelliseen laskentaan, tekoälyyn ja datan käsittelyyn.

Pythonin suosiota selittää sen helppokäyttöisyys ja monipuolisuus. Se on yksinkertainen ja selkeä kieli, joka helpottaa koodin lukemista ja ymmärtämistä myös aloittelijoille. Pythonilla on myös laaja valikoima kirjastoja ja työkaluja, jotka tekevät sen käytöstä entistäkin monipuolisempaa ja tehokkaampaa.

Eräs tärkeimmistä ominaisuuksista, joka erottaa Pythonin muista ohjelmointikielistä, on sen dynaaminen tyyppijärjestelmä. Tämä tarkoittaa sitä, että muuttujien ei tarvitse olla ennalta määritellyjä tietyille datatyypille ja niitä voidaan vaihtaa sujuvasti ohjelman suorituksen aikana. Tämä tekee koodin kirjoittamisesta ja ylläpitämisestä joustavampaa ja helpompaa.

Pythonin avoimen lähdekoodin luonne tekee siitä erittäin suosittua ja käyttäjien keskuudessa arvostetun ohjelmointikielen. Sen avulla kehittäjät ympäri maailmaa voivat tehdä yhteistyötä ja luoda innovatiivisia ratkaisuja erilaisiin ongelmiin. Pythonilla on myös laajat standardikirjastot, jotka tarjoavat valmiita työkaluja erilaisten tehtävien suorittamiseen, sekä laaja yhteisö, joka tukee ja auttaa ohjelmoijia erilaisissa kysymyksissä ja ongelmatilanteissa. Yhteisön luoma sisältö, kuten opetusmateriaalit ja kirjastot, ovat myös vapaasti saatavilla ja voivat auttaa nopeuttamaan ohjelmointiprosessia.

Python on myös erittäin monipuolinen kieli, joka soveltuu hyvin erilaisiin tarkoituksiin. Sen avulla voi kehittää niin web-sovelluksia, tietokantoja, peliohjelmointia kuin tekoälysovelluksia. Erityisesti datatieteen ja tekoälyn alalla Pythonin suosio on kasvanut huimasti viime vuosina. Kielen avulla voidaan käsitellä valtavia määriä dataa ja soveltaa erilaisia tekoälyalgoritmeja. ("History of Python," 2019).

Scikit-learn, eli SKLearn, on avoimen lähdekoodin Python-kirjasto, joka tarjoaa tehokkaita työkaluja koneoppimiseen. Se sisältää laajan valikoiman algoritmeja sekä luokitteluun, regressioon, ryhmittelyyn että dimension vähentämiseen. SKLearn tukee myös monimutkaisempia koneoppimisprosesseja, kuten datan esikäsittelyä, mallin validointia ja hyperparametrien optimointia. Kirjasto on suosittu sen helppokäyttöisyyden, monipuolisuuden ja hyvän dokumentaation vuoksi, mikä tekee siitä sopivan työkalun niin tutkijoille kuin kehittäjillekin koneoppimissovellusten rakentamiseen. (User guide: contents n.d.)

8 Malli, sen toiminta ja tulokset

8.1 Datan lähteet, formaatti ja validointi


Datan lähteinä toimivat yrityksen ajoneuvolistaus, kunnossapitokustannukset talouden järjestelmistä, sekä kilometritiedot ajoneuvojen seurantajärjestelmästä. Data yhdistettiin ja muotoiltiin koneoppimisalgoritmien käsittelemään muotoon. Mallia kokeiltiin kahdella eri lähestymistavalla:

1. Ajoneuvot anonymisoitiin ja rakennettiin lista eri ikäisistä ajoneuvoista ja niiden kustannuksista ja kilometreistä
2. Ajoneuvon kustannuksia pyrittiin ennustamaan ottamalla huomioon ajoneuvon edellisen vuoden kustannukset

Anonymisointivaiheessa datasta muodostettiin taulukko, jossa ajoneuvon tunnistetiedot poistettiin ja jossa sama ajoneuvo voi esiintyä useaan kertaan eri ikäisenä. Esimerkiksi ajoneuvo voi olla listalla 5-vuotias 2021 vuoden kustannus- ja kilometridatalla ja taas 6-vuotias 2022 datalla. Koneoppimismallia kokeiltiin myös ilman anonymisointia, ottamalla mukaan ajoneuvon edellisen vuoden kustannukset. Tässä ennustemalli rakennettiin vuoden 2022 datalla, ottaen mukaan edellisen vuoden kustannukset ja kilometrit. Tässä tapauksessa ajoneuvolle siis rakentuu historiatietoa kunnossapitokustannuksille, joskin vain lyhyeltä ajalta. Mallin opettamiseen käytettiin vain vuosien 2021 ja 2022 dataa. Vuoden 2023 dataa käytettiin ainoastaan validointiin, eikä koneoppimismalli päässyt hyödyntämään sitä missään vaiheessa.


Datassa oli huomattavia epätarkkuuksia, sillä ajoneuvojen kustannukset vaihtelevat rajusti vuositasolla. Osasyynä tälle voi olla väärin kirjatut kustannukset. Esimerkiksi vauriokorjausten kustannukset ovat usein melko suuria summia. Nämä ei kuitenkaan ole samalla tavalla ajoneuvon ikään tai kertyviin kilometreihin sidonnaisia, joten ne vääristävät dataa ja sitä kautta ennustemallia päätyösään kunnossapitokustannus-tilille. Toinen syy kustannusten vaihteluun on vanhenevissa ajoneuvoissa ilmenevät yksittäiset kalliit korjaukset, kuten vaihteisto- ja moottoriviat. Esimerkit datamalleista löytyvät liitteessä 3.

Ajoneuvon iän ja kustannusten välistä suhdetta on hankala havaita (Kuvio 11), mutta kilometrisuoritteella on havaittavissa oleva vaikutus (Kuvio 13). Tämä antaa ymmärtää, että kilometreillä voi olla suora vaikutus ajoneuvon kustannuksiin, ja tämä onkin melko kiistatonta. Esimerkiksi määräaikaishuollot tehdään monesti kilometrienperusteella, joten nousevat kilometrit johtavat nouseviin määräaikaishuoltojen kustannuksiin. Kuitenkin on havaittavissa, etteivät €/km kustannukset pysy vakiona kilometrien lisääntyessä, vaan ne vaikuttavat laskevan.



Kuvio 13: Ajettavien kilometrien ja ajoneuvotyypin vaikutus €/km -kustannuksiin

Kun tarkastellaan kokonaiskustannusten muutosta ikävuosittain vuosien 2021 ja 2022 välillä, on vaikea havaita johdonmukaista muutosta (Kuvio 14). Osassa ajoneuvoista kokonaiskustannukset ovat pudonneet reilusti vuosien välillä, ja osassa nousseet. Mikäli kaikkien ajoneuvojen kustannukset olisivat nousseet, olisi vastaava ennustemalli voitu toteuttaa helpomminkin, käyttämällä esimerkiksi pelkkää mittarilukemaa tai ikää ennustamaan kustannuksia. Kuitenkin jo tämän perusteella on syytä kokeilla, saako koneoppimismalli poimittua datasta syitä ja seurauksia, mitkä olisivat vaikeita havainnoida pelkällä datan visualisoinnilla.



Kuvio 14: Ajoneuvojen vuosittaisten kustannusten muutokset ikävuosittain vuosien 2021 ja 2022 välillä

8.2 Random Forest Regressor-mallin tulokset

Random Forest Regressor antoi kokeilluista malleista parhaan tuloksen. Se onnistui menetelmällä, missä ennustemalli otti huomioon edellisen vuoden kustannukset. Se välttyi pahimmalta ylisovitukselta ja sai siten aikaan kohtuullisen tarkan ennusteen koko vuoden kustannuksista, vain n. 2 %

virheellä. Edellisen vuoden kustannukset ja arvioidut kilometrit olivat tärkeimmät muuttujat vaikutuksiltaan. Sama pätee muihinkin malleihin, koska ajoneuvo, joka on ollut kallis huoltaa, on useassa tapauksessa kallis myös jatkossa. Ennusteen kohteena oli €/km, joten loogisesti kilometrit ovat tärkeä muuttuja ennustemallille. Iän ja ajoneuvoa operoivan yksikön vaikutukset jäivät edellä mainittuja pienemmäksi, mutta silti tärkeiksi muuttujiksi. Ajoneuvon tyyppin ja merkin vaikutukset jäivät niin pieniksi, että ne voitiin jättää mallista kokonaan pois.

Taulukko 1: Muuttujien vaikutukset ennustemalliin Random Forest Regressor-mallilla.

Muuttuja	Vaikutus
Kilometrit 2022	0,692
Kilometrit 2021	0,114
Kustannukset 2021	0,072
Mittarilukema 2022	0,052
Ikä	0,029
Malli	0,018
Yksikkö	0,018
Keräystapa	0,014
Merkki	0,009

Mallin tuloksen keskineliösumma (Mean squared error) oli 0,0189 ja selitysaste R^2 oli 0,7931. Keskineliösumma kuvaa hajonnan määrää joukossa. Se lasketaan kaavalla:

$$MSE = \frac{\sum(\text{todellinen} - \text{ennustettu})^2}{n}$$

Missä: n – näytekoko, todellinen – datapisteen todellinen arvo, ennustettu – datapisteen ennustettu arvo

Mikäli arvo on nolla, on ennustemalli onnistunut täydellisesti, tai on kyse ylisovittamisesta. (Frost 2021).

R^2 Kuvaa mallin muuttujien vaikutusta mallin kyvykkyyteen. Sen arvo on välillä 0 ja 1, jossa 1 kuvaa mallia, mikä kykenee ennustamaan kohteensa täydellisesti annetuilla tiedoilla. Mikäli tuloksena on

0, tarkoittaa se, että malli ennustaa samaa tulosta sille annetuista tiedoista huolimatta. (sklearn.metrics.r2_score n.d.).

Taulukko 2: Random Forest Regressor -mallin pisteytys

Mittari	Pisteytys
Mean Squared Error:	0,0163
score (R^2):	0,8215


8.3 Muut mallit

Huonoiten malleista pärjäivät SVR ja Ridge, mutta myös Lasso ja ElasticNet olivat selkeästi Random Forest Regressor -mallia huonompia. Sen sijaan toinen Ensemble-malli, Gradient Boosting Regressor pärjasi muita malleja paremmin, mutta hieman huonommin kuin Random Forest Regressor. Mallien pisteytykset löytyvät liitteestä 4.

8.4 Tulokset


Käytetty koneoppimismalli perustui regressiomalliin, jossa huomioitiin erilaisia tekijöitä kuten ajoneuvon ikä, kilometrimäärä. Lisäksi malli hyödynsi historiallista dataa kunnossapitokustannuksista. Parhaiten toiminut malli pystyi ennustamaan 10 kappaletta 22 kalleimmasta ajoneuvosta. Kuitenkin kaikkien mallin ennustamien autojen kustannukset olivat korkeat ja ne vastasivat 86 % kokonaiskustannuksiltaan kalleimpien 22 ajoneuvon kustannuksia ja 53,2 % kokonaiskustannuksista.

Verrattuna korvausstrategiaan, jossa toteutuneiden kustannusten kalleimmat 10 % vaihdetaan, koneoppimismallilla päästiin hieman parempaan tulokseen. Mikäli korvaussuunnitelma olisi toteutettu kyseisen mallin mukaan, olisi korvattu vain 7 kpl 22 kalleimmasta ajoneuvosta. Kokonaiskustannukset näiden korvattavien ajoneuvojen osalta olisi vastanneet 83 % kalleimpien 22 ajoneuvon kustannuksista ja 51,6 % kokonaiskustannuksista. Ero näiden kahden mallin välillä oli noin 1,5 % koko verrattavan kaluston vuosittaisista huoltokustannuksista.



Kuvio 15: Ennustemallin ajoneuvokohtainen tarkkuus

Kahta edellistä mallia voidaan verrata myös eräänlaiseen kolikon heittoon, jossa valikoidusta 43 ajoneuvosta valitaan satunnaisesti 22 kappaletta ja lasketaan näiden osuus kokonaiskustannuksista. Toistettuna koe 10 000 kertaa, saadaan tulokseksi seuraava kuvaaja:



Kuvio 16: Satunnaisesti poimittujen ajoneuvojen kustannukset

Koneoppimismallin tulos 53,2 % on suurempi kuin 84 % satunnaisesti arvottujen ajoneuvojen kustannuksista, kun taas verrattavan mallin tulos 51,6 % on suurempi kuin 60 % vastaavista. Koneoppimismalli pystyi siis ennustamaan ajoneuvojen kustannukset riittävällä tarkkuudella, että sen avulla kyettiin poimimaan kalleimmat ajoneuvot selvästi tehokkaammin kuin verratulla menetelmällä, jossa korvattiin ajoneuvot edellisvuoden kustannusten mukaan. Sen sijaan valitsemalla ajoneuvot edellisen vuoden kustannusten mukaan ei eronnut merkittävästi siitä, että ajoneuvot valitaan sattumanvaraisesti.

Mallin heikkous on sen ylisovittaminen. Kun ennustemallin 2023 vuoden ennustetta verrattiin vuoden 2023 toteumaan, sen MSE oli 0,2. Tämä tarkoittaa, ettei tämäkään malli pysty vielä kovin suurella tarkkuudella ennustamaan yksittäisen ajoneuvon tulevia kustannuksia kovin tarkalla tasolla.

Tarkkuus todennäköisesti lisääntyisi, mikäli data olisi virheettömämpää ja sitä olisi saatavilla pidemmältä aikaväliltä. Kuitenkin saatavilla olevaan dataan nähden tulos on hyvä ja se pystyy ennustamaan riittävällä tarkkuudella koko kaluston kunnossapitokustannusten kasvua, mikä riittää budjetoinnin ja omaisuudenhallintasuunnitelman tarpeisiin

8.5 Mallin käyttö korvauspäätöksen tukena

Mallia hyödynnettiin ennustamalla kunnossapitokustannukset seuraavalle kolmelle vuodelle ja ennusteen perusteella valittiin seuraavalle vuodelle korvattavat ajoneuvot ennalta määrätyn budjetin rajoitteita noudattaen. Korvattavat ajoneuvot valittiin ennalta määritellystä ryhmästä, jonka ajoneuvot olivat tarpeeksi vanhoja uusittavaksi, mutta eivät niin vanhoja, ettei niiden todellisia kustannuksia pystyisi ennustamaan. Liian vanhaksi kategorisoidut ajoneuvot olivat niitä, joita korvattiin näillä korvattavien ajoneuvojen ryhmästä valituilla yksilöillä, jotka taas korvattiin uusilla ajoneuvoilla. Tällä saatiin mahdollisimman suuri vaikutus keski-ikään, kokonaiskustannuksiin ja tehokkuuteen.

Myös sitä seuraavalle kahdelle vuodelle tehtiin budjetäärinen arvio korvattavien ajoneuvojen määrästä, sekä niiden vaikutuksesta kunnossapitokustannuksiin, leasingvastuisiin ja taseeseen. Laskelmat tarkastetaan kerran vuodessa menneen vuoden datan perusteella ja arviota korjataan tarvittaessa, kuitenkin ensimmäisen vuoden kustannusennuste koko ajoneuvokannalle erosi toteumasta vain yhdellä prosentilla.

Korvauspäätöksessä tulee ottaa huomioon myös muita tekijöitä, kuin kunnossapitokustannukset, mutta näiden ja ajosuorituksen ennustaminen on muihin tekijöihin verrattuna melko hankalaa. Kunnossapitokustannuksiin vaikuttaa todennäköisesti moni muuttuja, joita on vaikea mitata, kuten ajoneuvon käyttö, kiihdytykset ja jarrutukset. Myös saman merkin ja mallin eri vuosimalleilla saattaa olla eroja, joita omistaja tai käyttäjä ei välttämättä näe, kuten vaihtunut komponenttitoimitaja. Nämä saattavat vaikuttaa kunnossapitokustannuksiin siten, että sitä on vaikeaa ennustaa. Lisäksi kuljetusliiketoiminta on hyvin dynaaminen ala, joten ajoneuvon käyttökohde saattaa vaihtua useasti sen elinjakson aikana. Ei ole myöskään harvinaista, että ajoneuvo menee onnettomuuden seurauksena käyttökelvottomaan kuntoon iästä tai kilometreistä riippumatta, ja tällä on suuri vaikutus tehtyihin korvaussuunnitelmiin.


Polttoainekulut riippuvat hyvin paljon ajetuista kilometreistä ja uuden ja vanhan ajoneuvon erotus voidaan ottaa huomioon käyttämällä näiden keskimuutusta. Pääomakustannukset taas riippuvat lähinnä hinnasta ja rahoitustavasta. Ajoneuvon jäännösarvo myyntihetkellä on myös kustannustekijä, jota hankala arvioida, varsinkin kauas tulevaisuuteen, mutta sen vaikutus kokonaiskustannuksiin on huomattavasti pienempi kuin kunnossapidon, varsinkin vanhemman ajoneuvokaluston kohdalla, joten epätarkkuus voi olla hyväksyttävää.

9 Pohdintaa

9.1 Kuljetusalan kustannusrakenne suomessa

Tilastokeskus päivittää säännöllisesti tilastoa kuljetusyritysten kaluston kustannusjakaumasta. Vuoden 2023 lopun tilaston (**Virhe. Viitteen lähde ei löytynyt.**) mukaan esimerkiksi segmentin B pääoman poistot ja korot olivat vajaa 20 % kalusto kokonaiskustannuksista, kun esimerkiksi kunnossapitokustannukset olivat noin 7 %. Ainoa pääomakustannuksia suurempi kustannuserä on kuljettajien palkat noin 27 %:n osuudellaan.

Voidaan todeta, että merkittävä määrä kuljetusyrityksen kustannuksista syntyy kalustosta, sen operoinnista ja olemassaolosta. Läpinäkyvää logistiikka -uutiskirjeen mukaan SKALin tilastot kertovat kuljetusalan yrityksen liikevaihdon mediaanin olevan 840 500 euroa ja tilikauden tuloksen mediaanin 27 000 euroa (Sundström 2023). Viime vuosina on havaittu kuljetusalan olevan riskialtista toimintaa, muun muassa nousseiden polttoaineen ja uusien ajoneuvojen kustannusten takia. On siis tärkeää, että kuljetusyritykset pitävät kannattavuudestaan huolta, ja panostavat kalustonsa ja kalustonhallintaprosessiensa tehokkuuteen, jotta liiketoiminnan tuotto vastaa otettuja riskejä.



A= Pakettiautot ja kevyet kuorma-autot
 B= Keskiraskaat ja raskaat kuorma-autot
 C= Perävaunuyhdistelmät

Tilastokeskus

Kuvio 17: Kuljetusyritysten kaluston kustannusjakauma eri segmenteissä ((Tilastokeskus 2023) kuten ilmaistu Läpinäkyvää logistiikkaa -uutiskirjeessä (Sundström 2023)).

9.2 Eri hankintamallit ja niiden vaikutukset talouden mittareihin

9.2.1 Rahoituksen vaihtoehdot

Hankkiessa uutta laitetta, kuten ajoneuvoa, on olemassa useita eri rahoitusvaihtoehtoja, joita yritykset voivat hyödyntää. Perinteinen tapa rahoittaa ajoneuvon hankinta on ottaa pankkilaina. Tässä tapauksessa lainanottaja saa pankilta lainan, jolla hän ostaa ajoneuvon ja laina maksetaan takaisin sovittujen ehtojen mukaisesti, korkojen kera. Ostajalla on mahdollisuus vähentää lainan korot verotuksessa. Omistusoikeus siirtyy heti ostajalle ja ajoneuvoa voidaan käyttää vakuutena. Laina vaatii yleensä käsirahan ja voi vaikuttaa lainanottajan luottokelpoisuuteen.

Leasing on myös suosittu vaihtoehto, joka tarjoaa joustavuutta. Leasing-sopimuksia on useita erilaisia eri ehdoilla, mutta usein ne jaetaan kahteen eri kategoriaan, käyttöleasing- ja rahoitusleasing-sopimukseen. Käyttöleasing-sopimuksessa asiakas maksaa käytöstä kuukausimaksua, mutta ei koskaan omista ajoneuvoa tai laitetta. Sopimus sisältää usein myös kunnossapito-osuuden ja mah-

dollisesti muita käyttöön liittyviä kustannuksia. Sopimuksen jälkeen laite palautetaan leasingyhtiölle, joka kantaa jäännösarvoriskin. Rahoitusleasing-sopimuksessa asiakkaalla on mahdollisuus lunastaa laite sopimuksen lopussa, ja se muistuttaa hyvin paljon pankkilainaa, missä laite itsessään on lainan vakuutena. Tässä vaihtoehdossa asiakas kantaa jäännösarvoriskin ja vastaa ylläpitokustannuksista sopimuskauden ajan.

Myös vuokraus on yksi mahdollinen tapa hankkia uutta kalustoa, varsinkin ajoneuvojen osalta. On olemassa useita yrityksiä, jotka tarjoavat vuokra-ajoneuvoja eri tarkoituksiin, usein lyhyisiin, alle vuoden mittaisiin sopimuksiin. Vuokrasopimuksissa asiakas maksaa yleensä kiinteää hintaa, joka sisältää suurimman osan laitteen kustannuksista, kuten kunnossapidon ja vakuutukset, jolloin kustannusvaikutusten ennustaminen on erityisen helppoa. Vuokraaminen onkin hyvä keino lisätä kaluston joustavuutta, joka mahdollistaa vastaamisen lyhyellä ajanjaksolla nousevaan käyttötarpeeseen.

Yksi merkittävä rahoituskeino on oman pääoman käyttö, mikäli se on yritykselle mahdollista. Selkeinä etuina muihin vaihtoehtoihin on korko- ja muiden rahoituskulujen puute, mutta on kuitenkin suotavaa laskea tapauskohtaisesti, onko tämä tehokas tapa käyttää omaa pääomaa. Yritys voi laskea oman pääoman kustannukset esimerkiksi CAPM-mallilla:

$$ER_i = R_f + \beta_i(ER_m - R_f)$$

Missä: ER_i = Odotettu tuotto, R_f = Riskitön korko, β_i = Sijoituksen beta, eli riski suhteessa markkinaan, $(ER_m - R_f)$ = Markkinariskipreemio. (What Is the Capital Asset Pricing Model (CAPM)? 2023).

Mikäli yrityksellä on ennestään velkaa, on syytä ottaa huomioon kaikki yrityksen rahoituskustannukset ja käyttää Weighted Average Cost of Capital -laskentakaavaa (WACC):

$$WACC = \left(\frac{E}{V} \times Re \right) + \left(\frac{D}{V} \times Rd \times (1 - Tc) \right)$$

Missä: E = Oma pääoma, D = Vieras pääoma, $V = E + D$, Re = Oman pääoman kustannus, Rd = Vieraan pääoman kustannus, Tc = Yritysvero-%

WACC on yrityksen rahoituskustannusten keskimääräinen määrä, joka ottaa huomioon sekä oman että vieraan pääoman kustannukset. WACC on tärkeä mittari, sillä se kuvaa yrityksen rahoituksesta aiheutuvaa keskimääräistä kustannusta ja sitä käytetään usein investointien arvonmäärittämisessä ja taloudellisessa suunnittelussa arvioimaan projekteja ja sijoituksia. (Weighted Average Cost of Capital (WACC) Explained with Formula and Example 2024).

Valinta eri rahoitusvaihtoehtojen välillä riippuu useista tekijöistä, kuten:

- Budjetti ja kassavirta
 - Kuinka paljon organisaatiolla on varaa sitoa rahaa ajoneuvoihin?
- Ajoneuvon käyttötarve ja -tiheys
 - Kuinka usein ja kuinka pitkään ajoneuvoa tarvitaan?
- Verotus ja kirjanpidolliset seikat
 - Miten eri vaihtoehdot vaikuttavat kirjanpitoon, verotukseen ja talouden mittareihin?
- Riskienhallinta
 - Halutaanko riskejä hallita omistamalla ajoneuvoja tai vuokrata ajoneuvoja ulkopuolelta.

Näiden rahoitusvaihtoehtojen ymmärtäminen ja niiden vertailu perustuen organisaation tarpeisiin voi auttaa valitsemaan parhaan mahdollisen vaihtoehdon ajoneuvojen hankintaan. Jokaisella menetelmällä on omat etunsa ja haittansa, ja niiden soveltuvuus riippuu yrityksen toimintamallista, taloudellisesta tilanteesta sekä ajoneuvojen käyttötarpeesta.

9.2.2 Vaikutus kirjanpidossa

Suurin osa suomalaisista yrityksistä käyttää Finnish Accounting Standardsin (FAS) mukaista kirjanpitoa, jossa leasing-kulut merkitään kokonaisuudessaan tuloslaskelmaansa kuluksi. Ne ovat siten myös kokonaisuudessaan verovähennyskelpoisia. Kuluiksi kirjattuna ne eivät kasvata tasetta, joka saattaa olla haluttua, esimerkiksi koko pääoman tuottoasteen (ROA) kannalta. Yritykset voivat halutessaan käyttää myös kansainvälistä International Financial Reporting Standardsin mukaista mallia (IFRS) tilinpäätösraportointiin. Kirjanpitolain luvun 7a mukaan IFRS:n mukainen tilinpäätös pakollista julkisesti noteeratuille yhtiöille (Kirjanpitolaki 2004), mutta organisaatio voi siirtyä käyttämään sitä myös vapaaehtoisesti

Vuodesta 2016 kirjanpitolain säännös 5:5b on mahdollistanut IFRS: mukaisen kirjanpitokäytännön vuokrasopimusten, sekä rahoitusleasingin, että käyttöleasingin osalta myös FAS-kirjanpitokäytäntöä käyttäville organisaatioille, niin kauan kuin tietyt ehdot täyttyvät ja käytäntöä käytetään johdonmukaisesti kaikkiin vuokrakohteisiin (Rahoitusleasingia ei voi soveltaa elinkeinoverotuksessa 2021). Kirjanpitolain 5:5 b §:n mukaisesti vuokrasopimusten aktivointi on mahdollista, kun

- hyödykkeeseen perustuvat riskit ja edut siirtyvät olennaisilta osin vuokralle ottajalle sopimuskauden alkaessa, ja
- merkitsemiskäytäntöä sovelletaan samalla tavalla kaikkiin vuokrasopimuksiin, ja
- merkitsemisessä ja esittämisessä noudatetaan IAS-asetuksella hyväksytyjä tilinpäätösstandardeja eli edellä mainittua IFRS 16 Vuokrasopimukset –standardia (Lausunto KPL 5:5b §:n soveltamisesta - 2018)
- Sopimus on voimassa yli 12 kk

(Vuokrasopimusten aktivointi IFRS 16 -standardin mukaisesti 2019)

Vuokrasopimusten aktivoinnilla voi olla positiivisia vaikutuksia tiettyihin talouden mittareihin, kuten EBITDAhan, koska kaikkea vuokrakulua ei kirjata operointikuluksi, vaan se kasvattaa tasetta. Kyseinen tapa aktivoida vuokrakuluja taseeseen ei kuitenkaan ole yhdenmukainen suomen elinkeinoverolainsäädännön kanssa, jonka seurauksena tilinpäätöksen lukuja tulee oikaista vuokrien osalta perusteellisesti veroilmoitusta laadittaessa, mikä kasvattaa hallinnollista työtä (Rahoitusleasingia ei voi soveltaa elinkeinoverotuksessa 2021).

FAS:ia käyttävälle yritykselle, joka harkitsee siirtymistä IFRS:ään vuokrattujen omaisuuksien osalta, on tärkeää arvioida pitkän aikavälin strategiset hyödyt verrattuna välittömiin taloudellisiin vaikutuksiin. Vuokrauksen ja lainojen välisessä valinnassa tulisi ottaa huomioon paitsi kirjanpidolliset vaikutukset myös operatiiviset tarpeet, kuten ajoneuvojen vaihtuvuus, huoltokysymykset ja rahoituksellinen joustavuus. Näiden vaihtoehtojen harkinnassa on olennaista yhdistää yrityksen taloudellinen strategia sen operatiivisiin tavoitteisiin ja varmistaa, että toiminta on sopusoinnussa taloudellisten säännösten kanssa.

9.3 Koneoppimismallin käyttö tulevaisuudessa

Mielestäni tulokset osoittavat koneoppimismallien käytössä potentiaalia kunnossapitokustannusten ennustamiseen, jopa vajavaisella datalla. Vaikka ajoneuvo kohtaisten kustannusten ennustaminen on hankalaa, pystyy mallia hyödyntämään jo tällaisenaan esimerkiksi budjetoinnissa. Tämä antaa myös ajattelemisen aihetta yrityksille siitä, miten luotettavaa heidän keräämänsä data on ja onko mahdollisesti olemassa dataa, joka jää tällä hetkellä keräämättä, mutta mistä olisi hyötyä liiketoiminnalle.

Esimerkiksi laskutus, sekä osto-, että myyntilaskut, tuottavat valtavasti dataa yritykselle pitkällä aikavälillä. Ostolaskujen käsittelyssä tärkeää on laskun kohdistamisen lisäksi myös datankeruuta palveleva tilikartta. Myös laskun käsittelyn automatisoinnista voi olla suuri apu. Yksi haaste oli datan oikeellisuuden ohella sen kattavuus. Saatavillani oli kustannusdataa ainoastaan parilta edelliseltä vuodelta, joka oli eräs suurimmista haasteista autokohtaisen kustannusennustamisen osalta. Mikäli kustannusdataa olisi ollut pidemmältä aikaväliltä, olisi ehkä ollut mahdollista havaita enemmän autokohtaisiin kustannuksiin vaikuttavia tekijöitä.

Myös ajoneuvon käyttödataa olisi mahdollista yrittää hyödyntää rikastamaan koneoppimismallin käyttämää dataa. Ajoneuvon käyttökustannuksiin vaikuttaa se tapa, millä ajoneuvoa ajetaan (DriveTech 2020). Rajut kiihdytykset ja jarrutukset, suuri kuorma ja vaikeat olosuhteet voivat olla suuriakin tekijöitä siinä, kuinka kauan autoa on taloudellisesti järkevää pitää käytössä. Tämä vaatii kuitenkin kyseistä dataa hieman pidemmältä aikaväliltä, jotta sen vaikutukset kustannuksiin voidaan todentaa.

Ideaalitilanteessa kalustosta vastaavalla olisi saatavilla vähintään seuraavat tiedot hallittavista ajoneuvoista korvaussuunnitelman tekovaiheessa:

- Kunnossapitokustannukset
- Suunnitellut ja suunnittelemattomat huoltokäynnit, niiden pituudet ja syyt
- Ajoneuvon vuosittainen liikevaihto
- Perustiedot, kuten ikä, ajatut kilometrit ja ajoneuvon tyyppi
- Jatkuuko ajoneuvon tarve tulevaisuudessa
- Yksikkö, jossa ajoneuvo palvelee
- Korvauskustannus, ajoneuvon jäännösarvoarvio ja tasearvo

9.4 Muut lähestymistavat

Myös muiden koneoppimismallien kokeilu voi johtaa hyvään lopputulokseen. Esimerkiksi muuttamalla ongelman kuvaus muodosta ”mikä on ajoneuvon kustannus ensi vuoden lopussa” muotoon ”mitkä ajoneuvot on korvattava ensi vuonna”, voitaisiin mahdollisesti hyödyntää luokittelumallia. Tällainen lähestymistapa antaisi päättäjille valmiin vastauksen, siinä missä regressiomalli kertoo vain ennustetun kustannuksen. Mallin heikkous olisi kuitenkin se, että korvauksen rajat olisi määriteltävä ennalta, mikä toimii, mikäli organisaatio on linjannut omaisuudenhallintasuunnitelmassaan kalustolle raja-arvot esimerkiksi käyttökustannukselle tai elinjaksokustannuksille. Mikäli kuitenkin halutaan suunnitella korvausta pidemmälle tulevaisuuteen, on regressioennusteella arvoa esimerkiksi eri optimointimallien datalähteenä.

9.5 Mallin käyttö korvaussuunnitelman optimoinnin tukena

Mikäli organisaatio haluaa tehdä strategisen kaluston korvaussuunnitelman, esimerkiksi osana kalustonhallintasuunnitelmaansa, ja he haluavat sitoa sen yrityksen muihin tavoitteisiin ja mittareihin, on syytä arvioida kaluston korvausten vaikutusta pitkällä aikavälillä. Optimointimallit voivat olla avuksi tapauksessa, missä halutaan laskea kaluston korvauksen vaikutuksia tulokseen ja talouden muihin mittareihin. Tämä edellyttää kustannusrakenteen tarkkaa ymmärrystä, sekä kykyä ennustaa sitä pitkälle tulevaisuuteen, esimerkiksi koneoppimismallin avulla. Koska ajoneuvojen osalta myös kilometrit ovat tärkeässä osassa kaluston kustannusten kertymiseen, ja toisaalta kaluston kilometrit laskevat, mikäli kalusto on huonokuntoinen, on kyseessä haastava optimointiongelma.

9.5.1 Optimointiongelman luokittelu

Tämän kaltainen optimointiongelma, joka keskittyy useiden ajoneuvojen optimaalisen vaihtoajan määrittämiseen perustuen kustannustehokkuusvertailuihin vanhojen ja uusien ajoneuvojen välillä, on monitahoinen optimointihaaste, joka voidaan luokitella Mixed Integer Nonlinear Programming (MINLP) optimointiongelmaksi. Tavoitteena on minimoida kokonaiskustannukset, joihin sisältyvät käyttökustannukset, uusien ajoneuvojen kustannukset ja mahdollisesti vanhojen ajoneuvojen myynnistä saadut tulot. Vaihto tulisi suorittaa, kun vanhan ajoneuvon ylläpitämisen kustannustehokkuus heikkenee uuden ostamista huonommaksi. Ajoneuvon iän, käyttökustannusten ja tehok-

kuuden heikkenemisen suhde ajan myötä on tässä tutkimuksessa havaitun tiedon mukaan ei-lineaarinen. Vanhojen ajoneuvojen myyntihinta myös laskee ei-lineaarisesti ajoneuvon iän myötä (Fadzilah Salim & Nur Azman Abu 2021). Ongelma sisältää sekä jatkuvia muuttujia, kuten kustannukset ja hinnat, jotka voivat vaihdella jatkuvasti, että diskreettejä muuttujia, kuten tietty vaihtoaika. Kustannussuhteet ja ajoneuvon arvon aleneminen ovat ajan ja käytön funktiona ei-lineaarisia funktioita. Lisäksi päätös vaihdolle perustuen nykyisen ajoneuvon kustannustehokkuuden vertailuun uuden ajoneuvon kanssa tuo malliin ei-lineaarisuutta.

MINLP-ongelmien ratkaiseminen vaatii yleensä erikoistuneita algoritmeja, jotka pystyvät käsittelemään muuttujien sekalaisesta luonteesta ja tavoitefunktion sekä rajoitteiden ei-lineaarisuudesta aiheutuvaa monimutkaisuutta.

9.5.2 Ratkaisumenetelmät

Menetelmät, kuten Deterministic Dynamic Programming ja Stochastic Dynamic Programming, Simulated Annealing (SA), sekä Particle Swarm Optimization (PSO) ovat eräitä mahdollisia keinoja pyrkiä ratkaisemaan tämän kaltainen optimointiongelma.

Simulated Annealing on probabilistinen tekniikka, jota käytetään globaalien optimaalisen arvon likimääräiseen määrittämiseen annetulle funktiolle. Se on erityisen merkittävä kykynsä ansiosta löytää hyvä likimääräinen arvo suuressa etsintäavaruudessa, mikä on tehnyt siitä arvokkaan työkalun eri aloilla, kuten operaatiotutkimuksessa, taloustieteessä ja tietotekniikassa. Algoritmi on saanut alkunsa metallurgisesta prosessista, jossa materiaalia kuumennetaan ja sitten jäähdytetään hitaasti. SA jäljittelee tätä metallurgista käytäntöä ratkaisemaan optimointiongelmia. (What is Simulated Annealing? n.d.). Menetelmä esiteltiin ensimmäisen kerran vuonna 1983 Kirkpatrickin, Gelatin ja Vecchin toimesta sekä itsenäisesti Cernyn toimesta hieman myöhemmin (Bertsimas & Tsitsiklis 1993). Algoritmi pyrkii löytämään järjestelmän matalaenergiisiä tiloja tutkimalla etsintäavaruutta ja sallimalla probabilistiset siirtymät korkeaenergiisiin tiloihin. Tämä ominaisuus auttaa välttämään jummutumisen paikallisiin optimeihin, mikä tekee siitä tehokkaan monilla paikallisilla minimeillä varustetuissa ongelmissa. (Simulated Annealing 1997). SA:ta käytetään laajalti muun muassa Traveling Salesman ongelman ratkaisuun, mutta se on tehokas muissakin optimointiongelmissa, missä etsintäalue on diskreetti (Henderson, Jacobson & Johnson 2003).

Particle Swarm Optimization (PSO) on laskennallinen menetelmä, jota käytetään optimointiongelmien ratkaisemiseen eri tieteenaloilla. Menetelmä kehitettiin vuonna 1995 James Kennedyn ja Russell Eberhartin toimesta ja se sai inspiraationsa lintujen ja kalojen sosiaalisesta ja yhteistyöllisestä käyttäytymisestä. PSO:n perusajatuksena on, että ongelman ratkaisu voidaan löytää tehokkaammin ryhmän yhteistyöllä ja tiedon jakamisella kuin yksilön toiminnalla yksin. PSO perustuu partikkelien, eli potentiaalisten ratkaisujen, joukkoon, jotka liikkuvat ratkaisuavaruudessa. Jokainen hiukkanen edustaa potentiaalista ratkaisua optimoitavaan ongelmaan. Hiukkaset päivittävät sijaintiaan seuraamalla kahta pääkomponenttia: lokaalia parasta ratkaisua, jonka ne ovat tähän mennessä löytäneet, ja globaalia parasta ratkaisua (Gad 2022).

Deterministic Dynamic Programming (DDP) ja Stochastic Dynamic Programming (SDP) ovat kaksi lähestymistapaa, jotka kuuluvat dynaamisen ohjelmoinnin alueeseen. Ne tarjoavat keinoja ratkaista monivaiheisia optimointiongelmiä, joissa päätökset tai toimenpiteet yhdessä vaiheessa vaikuttavat seuraavien vaiheiden tilanteisiin ja lopputuloksiin. DDP käsittelee ongelmia, joissa kaikki tilanteeseen vaikuttavat tekijät ovat ennustettavissa ja muuttujat ovat deterministisiä. Toisin sanoen, ei ole epävarmuutta tai satunnaisuutta tilanteiden kehittämisessä seuraavien vaiheiden aikana. SDP ottaa huomioon epävarmuudet ja satunnaisuuden, joka liittyy päätöksenteon seurauksiin. Tämä lähestymistapa on tarpeen, kun toimenpiteiden tulokset ovat osittain tai kokonaan satunnaisia, ja näin ollen päätöksentekijä joutuu käsittelemään todennäköisyyksiä ja odotusarvoja. Molemmat lähestymistavat käyttävät dynaamisen ohjelmoinnin peruseriaatteita, jossa monivaiheinen ongelma jaetaan pienempiin, hallittavampiin osiin, ja ratkaisu rakennetaan yhdistämällä näiden osien ratkaisut. Ero näiden kahden menetelmän välillä on siinä, miten ne käsittelevät epävarmuutta päätöksenteon seurauksissa. (Fan ym. 2011)

9.5.3 Ratkaistavan ongelman määrittely

Organisaatiot voivat näitä menetelmiä hyödyntämällä kehittää heidän toimintaansa parantaakseen strategialleen merkittäviä mittareita, ei pelkästään ajoneuvonkalustonsa kyvykkyyttä, mikäli he pystyvät arvioimaan ja ennustamaan näihin vaikuttavia tekijöitä. Omaisuudenhallintajärjestelmän kulmakivenä on hallittavan omaisuuden tavoitteiden sitominen organisaation strategiaan tavoitteisiin ja usealla pk-yritykselläkin fyysinen omaisuus muodostaa erittäin tärkeän, ellei oleellisen osan organisaation kyvykkyyttä tehdä liiketoimintaa. Väitän, että organisaatio kokoluokasta riippu-

matta hyötyisi siitä, että he ottaisivat käyttöön omaisuudenhallintajärjestelmän omaisuudenhallintasuunnitelmiseen, sitoisivat fyysisen omaisuutensa tavoitteet organisaation liiketoiminnan tavoitteisiin, sekä käyttäisivät moderneja menetelmiä kustannusten ennustamiseen ja eri skenaarioiden mallintamiseen. Tämä työ on yksi esimerkki, miten tätä tavoitetta kohti voi ottaa ensimmäiset askeleet.

Lähteet

Ansari, Yahya 2023. Regularized Linear Regression. Medium. <https://medium.com/@novus_afk/regularized-linear-regression-35d5eaaa84d5> (luettu 14.4.2024).

Asset Management - An Anatomy 2015. Asset Management - An Anatomy. Asset Management - An Anatomy.

Bennet, Kristin P & Campbell, Colin 2000. Support Vector Machines: Hype or Hallelujah? 2000.

Bertsimas, Dimitris & Tsitsiklis, John 1993. Simulated Annealing. *Statistical Science*. 8(1). <<https://projecteuclid.org/journals/statistical-science/volume-8/issue-1/Simulated-Annealing/10.1214/ss/1177011077.full>>. DOI: 10.1214/ss/1177011077.

Dhumne, Shruti 2023. Elastic Net Regression detailed guide ! Medium. <<https://medium.com/@shruti.dhumne/elastic-net-regression-detailed-guide-99dce30b8e6e>> (luettu 14.4.2024).

Drivetech 2020. The impact of driver behaviour on vehicle running costs. <<https://www.drivetech.co.uk/wp-content/uploads/2020/07/Whitepaper-The-impact-of-driver-behaviour-on-vehicle-running-costs1.pdf>>.

Drucker, Harris, Burges, Christopher J. C., Kaufman, Linda, Smola, Alex & Vapnik, Vladimir 1996. Support Vector Regression Machines. *Advances in Neural Information Processing Systems*. Vsk. 9 MIT Press. <https://proceedings.neurips.cc/paper_files/paper/1996/hash/d38901788c533e8286cb6400b40b386d-Abstract.html>.

Fadzilah Salim & Nur Azman Abu 2021. Used Car Price Estimation: Moving from Linear Regression towards a New S-Curve Model. *International Journal of Business and Society*. 22(3), 1174–1187. DOI: 10.33736/ijbs.4293.2021.

Fan, Wei (David), Machemehl, Randy B. & Kortum, Katherine 2011. Equipment Replacement Optimization: Solution Methodology, Statistical Data Analysis, and Cost Forecasting. *Transportation Research Record: Journal of the Transportation Research Board*. 2220(1), 88–98. DOI: 10.3141/2220-11.

Frost, Jim 2021. Mean Squared Error (MSE). *Statistics By Jim*. <<https://statisticsbyjim.com/regression/mean-squared-error-mse/>> (luettu 15.4.2024).

Gad, Ahmed G. 2022. Particle Swarm Optimization Algorithm and Its Applications: A Systematic Review. *Archives of Computational Methods in Engineering*. 29(5), 2531–2561. DOI: 10.1007/s11831-021-09694-4.

Hastings, N. A. J. 2010. *Physical asset management*. London New York: Springer.

Henderson, Darrall, Jacobson, Sheldon H. & Johnson, Alan W. 2003. The Theory and Practice of Simulated Annealing. Glover, Fred & Kochenberger, Gary A (toim.), *Handbook of Metaheuristics*. International Series in Operations Research & Management Science. Boston: Kluwer Academic Publishers, 57: 287–319. <http://link.springer.com/10.1007/0-306-48056-5_10>. DOI: 10.1007/0-306-48056-5_10.

Kortelainen, Helena, Komonen, Kari & Laitinen, Jouko 2021. Tietämysperusteinen elinjakson hallinta. Kunnossapitoyhdistys Promaint ry.

Maklin, Cory 2018. Machine Learning Algorithms Part 11: Ridge Regression, Lasso Regression And Elastic-Net Regression. Medium. <<https://medium.com/@corymaklin/machine-learning-algorithms-part-11-ridge-regression-7d5861c2bc76>> (luettu 3.12.2023).

PAS 55-1 2008. PAS 55-1. BSI.

Sethi, Alakh 2020. Support Vector Regression Tutorial for Machine Learning. Analytics Vidhya. <<https://www.analyticsvidhya.com/blog/2020/03/support-vector-regression-tutorial-for-machine-learning/>> (luettu 3.12.2023).

Sharp, Tom 2023. An Introduction to Support Vector Regression (SVR). Medium. <<https://towardsdatascience.com/an-introduction-to-support-vector-regression-svr-a3ebc1672c2>> (luettu 3.12.2023).

Sundström, Anthony 2023. Läpinäkyvää logistiikkaa -uutiskirje.

Tilastokeskus 2023. Kuorma-autoliikenteen kustannusindeksi.

Toikko, Timo & Rantanen, Teemu 2009. Tutkimuksellinen kehittämistoiminta, Näkökulmia kehittämisprosessiin, osallistamiseen ja tiedontuotantoon. 2009. painos. Tampere University Press. <https://trepo.tuni.fi/bitstream/handle/10024/100802/Toikko_Rantanen_Tutkimuksellinen_kehittamistoiminta.pdf?sequence=1&isAllowed=y>.

Wilson, David, A. 2021. The Ultimate Guide to Commercial Vehicle Fleet Management. La Vergne: The DW Consultancy.

Simulated Annealing. 1997. (28.3.1997). <https://homepages.inf.ed.ac.uk/rbf/CVonline/LOCAL_COPIES/BMVA96Tut/node27.html> (luettu 14.4.2024).

Kirjanpitolaki. 2004. 7 a. Oikeusministeriö. <<https://www.finlex.fi/fi/laki/alkup/2015/20151620>>.

IEC 60300-1. 2014. 2014.

Lausunto KPL 5:5b §:n soveltamisesta -. 2018. (27.6.2018). Kirjanpitolautakunta. <<https://kirjanpitolautakunta.fi/-/lausunto-kpl-5-5b-n-soveltamises-1>> (luettu 13.4.2024).

Vuokrasopimusten aktivointi IFRS 16 -standardin mukaisesti. 2019. (31.10.2019). <<https://www.azets.fi/blogi/vuokrasopimusten-aktivointi-ifrs-16-standardin-mukaisesti/>> (luettu 11.4.2024).

Rahoitusleasingia ei voi soveltaa elinkeinoverotuksessa. 2021. (5.3.2021). PwC:n Uutishuone. <<https://uutishuone.pwc.fi/rahoitusleasingia-ei-voi-soveltaa-elinkeinoverotuksessa>> (luettu 11.4.2024).

Stacking Algorithms in Machine Learning - Analytics Vidhya. 2022. (22.11.2022). <<https://www.analyticsvidhya.com/blog/2022/11/stacking-algorithms-in-machine-learning/>> (luettu 14.4.2024).

Volvo Trucks cuts fuel use by 18% in road test. 2022. (14.12.2022). <<https://www.volvotrucks.com/en-en/news-stories/press-releases/2022/dec/volvo-trucks-cuts-fuel-use-in-road-test.html>> (luettu 15.1.2024).

What Is the Capital Asset Pricing Model (CAPM)? 2023. (22.12.2023). Investopedia. <<https://www.investopedia.com/terms/c/capm.asp>> (luettu 13.4.2024).

Building a Random Forest Model: A Step-by-Step Guide. 2024. (3.1.2024). <<https://www.analyticsvidhya.com/blog/2021/06/understanding-random-forest/>> (luettu 14.4.2024).

Gradient Boosting: A Step-by-Step Guide. 2024. (10.1.2024). <<https://www.analyticsvidhya.com/blog/2021/09/gradient-boosting-algorithm-a-complete-guide-for-beginners/>> (luettu 14.4.2024).

ISO/TC251 Contact. 2024. (21.3.2024). <<https://committee.iso.org/sites/tc251/home/contact.html>> (luettu 21.3.2024).

Käyttökate - mitä tarkoittaa käyttökate? (EBITDA). 2024. (2024). Procountor. <<https://procountor.fi/taloushallinnon-sanakirja/kayttokate-ebitda/>> (luettu 16.4.2024).

Weighted Average Cost of Capital (WACC) Explained with Formula and Example. 2024. (25.1.2024). Investopedia. <<https://www.investopedia.com/terms/w/wacc.asp>> (luettu 13.4.2024).

1.11. Ensembles: Gradient boosting, random forests, bagging, voting, stacking. n.d. scikit-learn. <<https://scikit-learn/stable/modules/ensemble.html>> (luettu 3.12.2023).

EN 16646:2015.

ISO 55000:2014.

ISO 55001:2014.

ISO 55002:2018.

ISO/TS 55010:2019.

sklearn.linear_model.Ridge. n.d. scikit-learn. <https://scikit-learn/stable/modules/generated/sklearn.linear_model.Ridge.html> (luettu 3.12.2023).

sklearn.metrics.r2_score. n.d. scikit-learn. <https://scikit-learn/stable/modules/generated/sklearn.metrics.r2_score.html> (luettu 15.4.2024).

User guide: contents. n.d. scikit-learn. <https://scikit-learn/stable/user_guide.html> (luettu 15.4.2024).

What is Simulated Annealing? n.d. <<https://www.cs.cmu.edu/afs/cs.cmu.edu/project/learn-43/lib/photoz/.g/web/glossary/anneal.html>> (luettu 14.4.2024).

Liitteet

Liite 1. Ennustemallin tulokset

Ensimmäisessä sarakkeessa toteutuneet kustannukset järjestyksessä suurimmasta pienimpään. Toisessa koneoppimismallin ennustamat kustannukset ensimmäisen sarakkeen ajoneuvoille. Kolmannessa sarakkeessa 2022 kustannusten perusteella ennustetut kustannukset ensimmäisen sarakkeen ajoneuvoille.

Kaiken kaikkiaan kalleimmat 22 ajoneuvoa vastasivat 62,1 % ennustettavien 42:n ajoneuvon kustannuksista. Ennustemallin kalleimmaksi päättelemät ajoneuvot vastasivat 53,2 % kokonaiskustannuksista, eli n. 9 % alle optimaalisen tuloksen.

Ajoneuvo	Toteuma % kokonaissummasta	Kustannusennuste % kokonaissummasta	Vuoden 2022 toteuman perusteella tehty korvauspäätös %
1	3,68 %	1,90 %	1,55 %
2	3,47 %	2,87 %	1,64 %
3	3,44 %	2,73 %	3,25 %
4	3,43 %	3,25 %	1,61 %
5	3,39 %	2,09 %	3,07 %
6	3,25 %	1,99 %	3,44 %
7	3,12 %	3,44 %	1,61 %
8	3,07 %	1,75 %	2,96 %
9	2,96 %	3,39 %	1,75 %
10	2,87 %	1,73 %	2,87 %
11	2,73 %	1,56 %	1,94 %
12	2,68 %	3,43 %	2,49 %
13	2,63 %	2,68 %	2,68 %
14	2,63 %	1,62 %	1,62 %
15	2,55 %	2,49 %	2,34 %
16	2,49 %	2,13 %	3,12 %
17	2,36 %	3,47 %	2,09 %
18	2,34 %	1,79 %	2,36 %
19	2,34 %	1,62 %	1,56 %
20	2,30 %	1,64 %	1,63 %
21	2,21 %	3,68 %	2,55 %
22	2,15 %	1,94 %	3,47 %
Välisumma	62,10 %	53,22 %	51,63 %
23	2,13 %	2,21 %	3,68 %
24	2,09 %	2,36 %	1,94 %
25	2,06 %	2,63 %	2,06 %
26	2,04 %	1,61 %	1,93 %

27	1,99 %	1,93 %	1,75 %
28	1,94 %	1,94 %	2,73 %
29	1,94 %	1,55 %	2,63 %
30	1,93 %	2,06 %	3,39 %
31	1,90 %	1,63 %	2,13 %
32	1,79 %	2,63 %	3,43 %
33	1,75 %	2,96 %	1,79 %
34	1,75 %	1,61 %	2,04 %
35	1,73 %	3,07 %	1,73 %
36	1,64 %	3,12 %	2,15 %
37	1,63 %	2,55 %	2,30 %
38	1,62 %	2,15 %	1,99 %
39	1,62 %	2,34 %	2,63 %
40	1,61 %	2,30 %	1,62 %
41	1,61 %	2,34 %	1,90 %
42	1,56 %	1,75 %	2,21 %
43	1,55 %	2,04 %	2,34 %

Liite 2. Koodi

```
from sklearn.ensemble import RandomForestRegressor
```

```
from sklearn.metrics import mean_squared_error
```

```
from sklearn.preprocessing import LabelEncoder
```

```
from sklearn.linear_model import ElasticNet
```

```
from sklearn.linear_model import Lasso
```

```
from sklearn.svm import SVR
```

```
from sklearn.linear_model import Ridge
```

```
from sklearn.ensemble import GradientBoostingRegressor
```

```
from sklearn.ensemble import AdaBoostRegressor
```

```
from sklearn.linear_model import LinearRegression
```

```
#Ladataan data
```

```
kalusto_df = pd.read_csv("autoluettelo.csv",header=0, delimiter = ";", parse_dates = ['Käyttöönottopäivä'],converters={'Autonumero': str})
```

```
kust_df = pd.read_csv("kustannukset.csv",header=0, delimiter = ";",converters={'Autonumero': str})
```

```
km_df = pd.read_csv("km.csv",header=0, delimiter = ";",converters={'Autonumero': str})
```

```
#Yhdistetään data
```

```
merged_df = pd.merge(kalusto_df, kust_df, on='Autonumero')
```

```
merged_df = pd.merge(merged_df, km_df, on='Autonumero')
```

```
#Käytetään LabelEncoderia muuntamaan osa datasta koneoppimismallin hyväksymään muotoon kategorioiksi
```

```
label_encoder = LabelEncoder()
```

```
merged_df['Keräystapa'] = label_encoder.fit_transform(merged_df['Keräystapa'])
```

```
merged_df['Department'] = label_encoder.fit_transform(merged_df['Department'])
```

```
merged_df['Merkki'] = label_encoder.fit_transform(merged_df['Merkki'])
```

```
merged_df['Malli'] = label_encoder.fit_transform(merged_df['Malli'])
```

```
#Laske ajoneuvon ikä käyttöönottopäivästä
```

```
from datetime import datetime
```

```
merged_df['Ikä'] = datetime(2023,11,14)-merged_df['Käyttöönottopäivä']
```

```
merged_df['Ikä'] = merged_df['Ikä'].apply(lambda x: x.days) /365
```

```
merged_df.drop('Käyttöönottopäivä', axis=1, inplace=True)
```

```
#Poista ajoneuvot jotka eivät aja
```

```
merged_df = merged_df.drop(merged_df[merged_df['Kilometrit 2021']<7000].index)
```

```
merged_df = merged_df.drop(merged_df[merged_df['Kilometrit 2022']<7000].index)
```

```
merged_df = merged_df.drop(merged_df[merged_df['2021']<10000].index)
```

```
merged_df = merged_df.drop(merged_df[merged_df['2022']<10000].index)
```

```
#Laske €/km
```

```
merged_df['€/km 2021'] = merged_df['2021']/df['Kilometrit 2021']
```

```
merged_df['€/km'] = merged_df['2022']/merged_df['Kilometrit 2022']
```

```
merged_df['€/km 2023'] = merged_df['2023']/merged_df['Kilometrit 2023']
```

```
# Jaa data muuttujiin X ja kohteeseen y
```

```
X = merged_df[['Ikä', 'Keräystapa', 'Merkki', 'Department', 'Kilometrit 2021', 'Kilometrit 2022', '2021', 'Mittarilukema 2022', 'Malli']]#
```

```
y = merged_df[['€/km']]
```

```
# Jaa data koulutus- ja validointiosiin
```

```
X_train, X_test, y_train, y_test = train_test_split(X, y, test_size=0.2, random_state=42)
```

```
# Kouluta malli
```

```
model = RandomForestRegressor(random_state=42, n_estimators=1000, n_jobs=-1)
```

```
model.fit(X_train, y_train)
```

```
# Tee ennuste
```

```
y_pred = model.predict(X_test)
```

```
# Laske MSE ja pisteytä

mse = mean_squared_error(y_test, y_pred)

print("Mean Squared Error:", mse)

print("score (R2): ", model.score(X_test, y_test))
```

Liite 3: Data

	Ikä	Keräystapa	Merkki	Department	Kilometrit 2021	Kilometrit 2022	Kustannukset2021	Mittarilukema 2022	Malli
1	9.484932	0	6	1	52901	30973.3	xxxxx	601008.6	54
2	8.569863	6	3	11	28393	29713.5	xxxxx	220030.6	31
5	9.200000	6	3	11	24435	34493.7	xxxxx	238451.7	23
6	11.232877	6	3	10	30592	13157.2	xxxxx	324594.6	23

Taulukko 3: Datamalli edellisen vuoden kustannuksilla

	Ikä	Keräystapa	Merkki	Kilometrit 2022	Kilometrit 2021	Mittarilukema 2022	Malli
1	9.484932	0	6	30973.3	52901	601008.6	54
2	8.569863	6	3	29713.5	28393	220030.6	31
5	9.200000	6	3	34493.7	24435	238451.7	23
6	11.232877	6	3	13157.2	30592	324594.6	23

Taulukko 4: Anonymisoitu datamalli

Liite 4: Muiden kokeiltujen mallien pisteytykset**Mittari Pisteytys**

Mean Squared Error 0,0650
score (R^2) 0,2879

Taulukko 5: SVR-mallin pisteytys

Mittari Pisteytys

Mean Squared Error 0,0524
score (R^2) 0,4257

Taulukko 6: ElasticNet-mallin pisteytys

Mittari Pisteytys

Mean Squared Error 0,0524
score (R^2) 0,4256

Taulukko 7: Lasso-mallin pisteytys

Mittari Pisteytys

Mean Squared Error 0,0900
score (R^2) 0,0132

Taulukko 8: Ridge-mallin pisteytys

Mittari Pisteytys

Mean Squared Error 0,0238
score (R^2) 0,7390

Taulukko 9: Gradient Boosting Regressor -mallin pisteytys

