



VAASAN AMMATTIKORKEAKOULU
UNIVERSITY OF APPLIED SCIENCES

Joonas Kevari

GENERATIIVINEN TEKOÄLY YRITYKSEN OMAN DATAN HYÖDYNTÄMISESSÄ

Tekniikka
2023

TIIVISTELMÄ

Tekijä	Joonas Kevari
Opinnäytetyön nimi	Generatiivinen tekoäly yrityksen oman datan hyödyntämisessä
Vuosi	2023
Kieli	suomi
Sivumäärä	58
Ohjaaja	Johan Dams

Tässä opinnäytetyössä toteutettiin työelämälähtöinen kehittämishanke, jossa generatiivista tekoälyä käytettiin yrityksen oman datan hyödyntämiseen. Kehittämishankkeen lähestymistavaksi valikoitui sen käytännönläheisyyden vuoksi työelämälähtöinen toimintatutkimus. Työn keskeisimpinä tavoitteina oli selvittää, pystytäänkö toteuttamaan pilvipalvelu, jossa käyttäjä pystyy esittämään kysymyksiä ja saamaan vastauksia, sekä pystyykö generatiivinen tekoäly hyödyntämään vastauksia antaessaan yrityksen omaa dataa.

Tekoäly ja erityisesti tekoälytutkimus on kasvanut suuresti viimeisen kahden vuosikymmenen aikana, mikä omalta osaltaan on ollut suuresti vaikuttamassa erilaisen generatiivisten tekoälymallien syntymisessä. Tekoäly on kattoterminä usealle eri alaluokalle, jolla on pyritty selkeyttämään tekoälyn käsitteistöä. Generatiivisella tekoälyllä voidaan tarkoittaa erilaisia generatiivisia malleja, jotka kykenevät luomaan tekstiä, kuvia tai ääntä. Tässä opinnäytetyössä keskityttiin tekstipohjaiseen generatiiviseen tekoölyyn, jonka avulla pyritään vastaamaan tutkimuskysymyksiin.

Tekoälyn kehittäminen Scrum-viitekehyksessä on iteratiivista ja toistuvaa toimintaa, joka sopii toimintatutkimuksen periaatteisiin hyvin. Tässä työssä toteutettiin ensimmäinen vaihe, jossa tuotettiin web-käyttöliittymä. Käyttöliittymässä voitiin esittää kysymyksiä tekoälymallille ja saamaan vastauksia, mutta myös koko pilviinfrastruktuuri myöhempää kehitystä varten. Työn lopputuloksena saatiin jatkokehitystarpeita, sekä arvioitua seuraavat kehityskohteet paremman tekoälyn lopputuloksen saamiseksi. Yrityksen datana käytettiin pdf-dokumentteja, sekä Jirassa olevaa tietoa, joka vietiin Azuren Cosmos DB -tietokantaan. Tekoäly kykenee antamaan selkeitä vastauksia pdf-dokumenteista, mutta Jira-datan hyödyntämisessä havaittiin selkeitä kehityskohteita, joita voidaan tulevien kehitysvaiheiden aikana parantaa erilaisin keinoin. Mahdolliset jatkokehitystarpeet ja niiden määrittely tapahtuu yrityksen toimesta.

Avainsanat	tekoäly, generatiivinen tekoäly, GPT, Azure, SaaS, toimintatutkimus
------------	---------------------------------------------------------------------

ABSTRACT

Author	Joonas Kevari
Title	Generative artificial intelligence in utilizing the company's own data
Year	2023
Language	Finnish
Pages	58
Name of Supervisor	Johan Dams

In this thesis, a working life-oriented development project was carried out, in which generative artificial intelligence was used to utilize the company's own data. Due to its practical approach, work-life-oriented action research was chosen as the approach chosen for the development project. The main objectives of the work were to find out whether a cloud service could be implemented where the user could ask questions and get answers, and whether generative artificial intelligence could utilize the company's own data when providing answers.

Artificial intelligence, and AI research in particular, has grown greatly over the past two decades, which has contributed greatly to the emergence of various generative AI models. Artificial intelligence is an umbrella term for several different sub-categories that have sought to clarify the concepts of artificial intelligence. Generative AI can refer to various generative models capable of creating text, images, or sound. This thesis focused on text-based generative artificial intelligence, which aims to answer research questions.

The development of artificial intelligence in the Scrum framework is an iterative and repetitive activity that fits well with the principles of action research. In this work, the first stage was carried out, in which a web interface was produced. In the user interface, it was possible to ask questions to the AI model and get answers, but also the entire cloud infrastructure for later development. As a result of the work, further development needs were identified, as well as the following development targets were evaluated to achieve a better result for artificial intelligence. The company's data was pdf documents, as well as information from Jira, which was exported to Azure's Cosmos DB database. Artificial intelligence may be able to give clear answers from pdf documents, but clear areas for development were identified in the utilisation of Jira data, which can be improved by various means during future development phases. Possible further development needs and their definition are carried out by the company.

Keywords	artificial intelligence, Generative AI, Azure, SaaS, Action research
----------	----------------------------------------------------------------------

SISÄLLYS

TIIVISTELMÄ

ABSTRACT

1	JOHDANTO.....	7
2	KEHITTÄMISHANKKEEN LÄHTÖKOHDAT	8
	2.1 Ajankohtaisuus ja tausta.....	8
	2.2 Tavoite ja tarkoitus	10
	2.3 Aiheen rajaus	12
3	TEKOÄLY.....	13
	3.1 Luonnollisen kielen käsittely.....	18
	3.2 Generatiivinen tekoäly.....	21
	3.3 GPT-3.....	23
	3.4 Kehotesuunnittelu	25
	3.5 Tekoälyn juridiset ja eettiset kysymykset	27
4	KEHITTÄMISHANKE MENETELMÄNÄ.....	29
5	KEHITTÄMISHANKKEEN TOTEUTUS.....	33
	5.1 Hankkeen suunnittelu.....	33
	5.1.1 Tarpeen määrittely.....	35
	5.1.2 Arkkitehtuuri	37
	5.2 Toteutus	39
	5.2.1 Käytettävä data ja datamalli	39
	5.2.2 Tekninen toteutus.....	40
	5.2.3 Testaus	45
6	TULOKSET	47
	6.1 Tulosten arviointi	47
	6.2 Kehitysehdotukset	49
	6.2.1 Data	49
	6.2.2 Käyttöliittymä.....	51
	6.2.3 Järjestelmäkokonaisuus ja käyttökohteet	52
7	POHDINTA.....	54

LÄHTEET	56
---------------	----

KUVIO- JA TAULUKKOLUETTELO

Kuvio 1. Tekoälyä käsittelevien julkaisujen määrä 1958–2017	10
Kuvio 2. Hankkeen rakenne opinnäytetyössä	11
Kuvio 3. Tekoälyn luokittelu	16
Kuvio 4. Kehityssykli NLP-sovelluksille	19
Kuvio 5. AI, ML, DL ja GAI-suhde	22
Kuvio 6. Spiraalimalli	30
Kuvio 7. Hankkeen rakenne	33
Kuvio 8. Aikataulusuunnitelma	34
Kuvio 9. Ratkaisun arkkitehtuuri	38
Kuvio 10. Datamalli	40
Kuvio 11. Kehityksen sisällä tapahtuva sykli	41
Kuvio 12. Azure Session Debugger	43
Kuvio 13. Käyttöliittymä	45
Kuvio 14. Azure openAI playground	46
Kuvio 15. Testaajien yleisarvio	48
Taulukko 1. Spiraalimallin ja Scrumin yhtenäisyydet	31
Taulukko 2. Hankkeen henkilöstö	35
Taulukko 3. Tarvemäärittely ja hyväksymiskriteerit.....	36
Taulukko 4. Indeksoinnin kenttäkonfiguraatiot	44

1 JOHDANTO

Ihmisiä viisaammilla tekoälyillä on leikitelty erityisesti elokuvatuotannossa jo useiden vuosien ajan, ja ne ovat tuottaneet ajoittain jopa villejä visioita tulevaisuuden tekoälystä. Onneksi olemme kuitenkin tekoälyn kohdalla vielä kaukana yhdestäkään näistä kauhukuvista. (Hiltunen & Hiltunen 2014.)

Tässä työelämälähtöisessä kehittämishankkeessa ei tavoitella robottien tekoälyn parantamista tai ihmisten emootioiden mallintamista tekoälyn maailmaan. Työssä toteutetaan osana laajempaa hankekokonaisuutta generatiivista tekoälyä hyödyntävä chat -palvelu pilviympäristöön, jonka tarkoituksena on hyödyntää yrityksen omaa dataa ja vastata käyttäjän esittämiin kysymyksiin.

Työ lähtee liikkeelle hankkeen tavoitteista, taustasta ja ajankohtaisuudesta, jonka jälkeen perehdytään tekoälyn osalta tärkeimpiin termeihin ja kokonaisuuksiin, jotka vaikuttavat erityisesti generatiiviseen tekoälyyn. Teoreettinen viitekehys ei kuvaa jokaista tekoälyn pääluokkaa ja alaluokkaa, vaan lukija voi nauttia matkasta kohti generatiivista tekoälyä. Työssä pohditaan myös tekoälyn etiikkaa ja juridisia kysymyksiä, jotka vaikuttavat tekoälyn kehittämiseen.

Työssä kuvataan myös se, mitä kehittämishanke on ja millainen on sen suhde tutkimukseen, mutta myös miten kehittämishankkeen periaatteet näkyvät työssä.

Lopulta työssä kuvataan myös hankkeen etenemistä ja itse chat palvelun toteuttamista pilviympäristössä, sekä pohditaan kokonaishankkeen seuraavia mahdollisia kehityskohteita, tuloksia unohtamatta.

2 KEHITTÄMISHANKKEEN LÄHTÖKOHDAT

2.1 Ajankohtaisuus ja tausta

Teknologisen kehityksen kuvataan olevan harvoin nopeaa, saati yhdessä yössä tapahtuva ilmiö. Teknologinen kehitys nähdäänkin enemmän evoluution kaltaisena kehityksenä, jossa erilaiset elementit kehittyvät vuosien saatossa, se elää ja kehittyy erityisesti vuoropuhelun kautta. Markkinoilla ja rahalla on kuitenkin suuri vaikutus siihen, mitä todellisuudessa tulee tapahtumaan. Tästä esimerkkinä voidaan pitää erilaisia uusia tarpeita tai toimintatapojen muutoksia, mutta se ei sulje pois myöskään kuluttajien asenteiden ja arvojen muutoksia. Teknologia synnyttää uusia markkinoita, mikä puolestaan synnyttää uusia tarpeita ja näin päästään ytimeen, jossa uusien tarpeiden syntyminen synnyttää jatkuvasti uusia innovaatioita ja markkinoita ympäristöömme. (Hiltunen & Hiltunen 2014.)


Myös yhteiskunnalla ja sattumalla on suuri vaikutus teknologisen kehittymisen suhteen, ne voivat myös hidastaa kehitystä. Erityisesti lainsäädännöllä on suuri vaikutus kehityksen kulkuun ja nopeuteen. Esimerkkejä voidaan hakea kauempaa-kin, mutta kannustavaa lainsäädäntöä on tehty esimerkiksi 2010-luvun taitepis-teessä, jolloin Suomen hallituksen päätöksellä siirryttiin digitaalisiin televisio lähe-tyksiin. Nykyisin Business Finland ohjaa julkista rahoitusta tiettyihin hankkeisiin ja näin ohjaa myös teknologian kehittymistä. Sattumalla on vaikutusta uusien inno-vaatioiden kohdalla, joista yksi tunnettu tapahtumasarja liittyy Alexander Flemin-giin, joka onnistui löytämään penisilliinin jätettyään bakteeriviljelmät kahden vii-
kon loman ajaksi työpisteelleen. (Hiltunen & Hiltunen 2014.)

Hiltunen ja Hiltunen (2014) nostavat omassa teoksessaan tekoälyn esille tulevai-suuden teknologiana. Jo vuonna 1993 oli ennustettu tekoälyn tulevan koteihin. Heikkoa tekoälyä on löytynyt jo Hiltusen ja Hiltusen (2014) teoksen kirjoittamisen aikana, mutta he nostavat esille myös IBM:n Watsonin tekemät sijoituspäätökset pörssissä sekä tekoälyrobotti Adamin, joka suoritti onnistuneesti tieteellisen tut-kimuksen ja tuotti hypoteesin. (Hiltunen & Hiltunen 2014.)

Kun tarkastellaan useamman vuoden takaisia teknologisia kehityskulkuja, jotka pohjautuvat tekoälyyn, voidaan huomata sen valtava kehittyminen viimeisen kymmenen vuoden aikana. Voikin vain pohtia, miten Teslan kehitys sekä Microsoftin ja Googlen tekoälypohjaiset ratkaisut ovat kaikki omalta osaltaan olleet mukana tekoälyn evoluutiossa.

Lähimenneisyydessä tekoäly on ottanut suuren loikan eteenpäin julkaisemalla Large Language Model -sovelluksen (LLM), ChatGPT:n, joka tuli julkisesti saataville. ChatGPT:n tulevaisuus näyttääkin valoisalta, sillä sen yhdistäminen muiden tekoälyn elementtien kanssa voi tuottaa suurta etua yrityksille ja yksittäisille ihmisille. Tästä on jo viitteitä, sillä keskustelu nykyisen mallin kanssa onnistuu ja sovelluksen käyttöliittymä on helppokäyttöinen. Erityisen mielenkiintoista on se, että se pystyy tunnistamaan käyttäjän tavat. Voidaankin todeta, että ChatGPT tarjoaa jo nyt mielenkiintoisia sovellettavan tekoälyn kohteita, joilla voidaan parantaa elämää arkisellakin tasolla. Vaikka sen vaikuttavuus yhteiskunnassa voi olla suurta, on ihmisten ja yhteiskunnan myös muistettava analysoida ja osoittaa sen eettisyyden perusta. (Hill-Yardin, Hutchinson, Laycock, & Spencer 2023; Aljanabi 2023.)

Tekoälytutkimuksessa julkaisujen määrä on ollut kovassa kasvussa lähes koko 2000-luvun (Kuvio 1.). Kiina ja Yhdysvallat ovat tekoälytutkimuksen selkeät suurvaltiot, sillä näiden kahden maan tieteellisten julkaisuiden kattavuus oli 36 % kaikista tekoälytutkimuksista. Vuorovaikutuksellisen tekoälytutkimuksen ja laskentaympäristön sekä ekosysteemien vuosittainen kasvu tutkimusjulkaisussa oli suurinta vuosien 2000–2017 välillä, jolloin näiden tutkimussuuntien vuosittainen kasvu oli 14,8 % laskentaympäristöihin, alustoihin ja palveluihin ja 13,3 % vuorovaikutukseen ihmisen kanssa. (Ailisto, Heikkilä, Helaakoski, Neuvonen, & Seppälä 2018., 25-38)



Kuvio 1. Tekoälyä käsittelevien julkaisujen määrä 1958–2017 (Ailisto ym. 2018, 26)

Tämä opinnäytetyö on toteutettu vaiheessa, jossa GPT-4 on julkaistu rajoitetusti saataville ja sen käyttäminen on rajattu ainoastaan maksaville asiakkaille. Lisäksi Microsoft on alkanut luoda ja julkaista erilaisia tekoälypalveluita, jotka pohjautuvat LLM-malliin, sekä muita yhteensopivuuksia mallin kanssa. Tässä työssä käytyt tekniset toteutukset ovat tekohetkellä olleet rajoitetusti saatavilla ja osa preview-vaiheessa ja siten kehitetty tai muutettu myöhemmin. Esimerkkinä Microsoftin copilot, joka toimii Azure-ekosysteemissä ja tulevaisuudessa muissakin Microsoft tuotteissa. (Microsoft 2023a; Microsoft 2023b)

Toteutus on tärkeä myös kohdeorganisaatiolle, sillä se haluaa olla mukana innovoimassa asiakkaiden parempaa huomista ja olla edelläkävijä digitalisaatiossa.

2.2 Tavoite ja tarkoitus

Tässä opinnäytetyössä toteutetaan työelämälähtöinen kehittämishanke, jossa tarkoituksena on toteuttaa pilvipalvelu, jossa käyttäjät pystyvät esittämään kysymyksiä ja saamaan näihin vastauksia. Kysymykset voivat koskea yrityksen sisäisiä tietoja, joita ei ole yleisesti saatavilla. Nämä tiedot tulee myös asettaa GPT:n saataville. Työssä on tarkoituksena käsitellä tarvittava määrä organisaation service desk

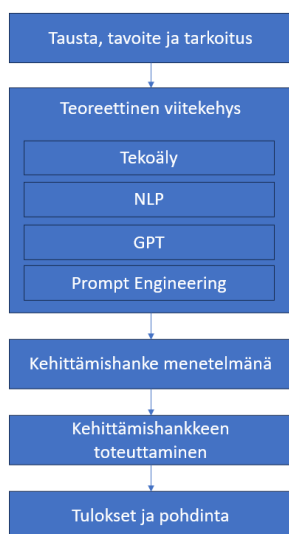
-palvelupyynnöitä tai muita potentiaalisesti tärkeitä tietoja, joiden avulla käyttäjät voivat kysyä kysymyksiä ja hakea vastauksia.

Tässä opinnäytetyössä on tarkoitus luoda pilvipalvelu, jonka avulla käyttäjät pystyvät esittämään kysymyksiä generatiiviselle tekoälylle, joka puolestaan pystyy vastaamaan kysymyksiin hyödyntämällä yrityksen omaa dataa.

Oleelliset kysymykset ovat:

1. Pystyttiinkö hankkeessa luomaan pilvipalvelu, jossa käyttäjä pystyy esittämään kysymyksiä GPT mallille ja saamaan vastauksia?
2. Pystyykö GPT hyödyntämään organisaation dataa vastauksia antaessaan ja näin luomaan arvoa käyttäjälle?

Työ etenee Kuvion 2. mukaisesti.



Kuvio 2. Hankkeen rakenne opinnäytetyössä

Työn teoreettinen viitekehys rakentuu syväluotaavasti tekoälykäsitteistön alimpiin osiin ja painottuu niihin tietoihin, jotka ovat oleellisia työn käytännön toteutuksen kannalta, eettistä näkökulmaa unohtamatta.

Koska kyseessä on kehittämishanke, noudattaa se toimintatutkimuksen periaatteita. Kehittämishankkeen toteutumista ja vaiheita kuvataan omina vaiheinaan.

Käytännön osuuden toteutumisen raportointi rakentuu kolmeen vaiheeseen. Vaiheet ovat: suunnittelu, toteutus ja arviointi.

Tulokset ja pohdinta arvioidaan edellä mainittujen kysymysten perusteella, mutta myös tutkimustoiminnan näkökulmasta, sekä arvioidaan toteutuksen mahdollisuuksia sekä kehityskohteita saadun palautteen perusteella.

2.3 Aiheen rajaus

Opinnäytetyön aihe ja toteutettava hanke on hyvin teknologiaorientoitunut, mutta tässä työssä lukijaa ei johdatella liian syväälle tekoälyn teknisiin haasteisiin tai kuvauksiin. Tekoäly ja siihen liittyvä tekninen toteutus painottuu niihin teknisiin tietoihin, mitä tarvitaan esimerkiksi Azure ympäristössä työskennellessä. Tekoäly on laaja termi ja tässä työssä käytettävä osuus käsittää sisällään vain pientä osaa koko tekoälyn spektristä. Työssä käsitellään NLP:n ja GPT:n käsitteistöä, sekä GPT:n toiminnallisuuksien tukemiseen liittyen kehotteen suunnittelun (prompt engineering) periaatteita ja käsitteistöä.

Työssä käsitellään tutkimustoiminnan periaatteita ja teoriaa toimintatutkimuksen näkökulmasta.

3 TEKOÄLY

Tekoälyn määritelmä ei ole yksiselitteinen tai selkeä, sillä se sisältää omia alaluokkia, jotka myös sisältävät usein omia alaluokkia. Se on kaiken kaikkiaan moniulotteinen ja koskettaa useita tieteenaloja. Onkin syytä huomioida, että tekoälyn tutkimuksen ja teknologisen kehitystä ei pidä ymmärtää toisistaan riippuvaisena, sillä tutkimuksellisen käytännön hyödyntäminen ja soveltamisen potentiaali saatavat edetä erilaisissa sykleissä. Esimerkiksi teknologisen kehityksen maturiteetin kehittyminen saattaa viedä vuosikymmeniä, kun soveltamisen sykli on yleensä 8–15 vuoden välillä. Samainen kehityskulku on havaittu myös tekoälyn osalta. Tekoälyn määrittämisen haasteen luo myös se, että tekoälyn alaluokat voivat myös osaltaan vaikuttaa itse tekoälyn määrittämiseen, kuten myös jokainen tieteenalansa voivat määrittää tekoälyn eri tavoin. (Ailisto ym. 2018.)

Russell ja Norvigin (2014) mukaan *”tekoälyn avulla koneet, laitteet, ohjelmat, järjestelmät ja palvelut voivat toimia järkevästi tehtävän tai tilanteen vaatimalla tavalla”*.

Tekoäly tuo paljon kysymyksiä, mutta antaa vähän vastauksia. Tekoälyn ympärillä nähdäänkin vahvasti kolme erityyppistä näkökulmaa tekoälyn ja ihmiskunnan tulevaisuudesta. Näistä ensimmäinen on teknologiakeskeinen näkökulma, joka näkee tulevaisuuden rakentuvan laajaan ja jatkuvasti kehittyvään potentiaaliin, jonka tekoäly tarjoaa. Kyseisen näkökulman omaavat, tekoälyn haasteista huolimatta, luottavat vahvasti tekoälyn ohittavan ihmisen älykkyydessä, yhdellä tai useammalla taholla. (Peeters ym. 2021.)

Ihmiskeskeisen näkökulman omaavat näkevät tekoälyn helpottavan ja parantavan ihmisten hyvinvointia, mutta sen ei kuitenkaan kokonaan uskota korvaavan ihmisiä. Näkökulman mukaan tekoäly pystyy toteuttamaan tehtäviä, jotka voivat olla esimerkiksi vaarallisia ihmisille. Tekoäly nähdään myös eriluontoisena älykkyytenä, joka lienee osasy sille, että ihmiskeskeisen näkemyksen omaavat tutkijat eivät usko tekoälyn korvaavan ihmistä. (Peeters ym. 2021.)

Kollektiivisen hybridiälykkyyden näkökulma pohjautuu ihmisen ja koneen yhteistyöhön, joka avulla pystytään parantamaan vallitsevaa älykkyyttä siinä kontekstissa, jossa ihminen on. Tätä kutsutaan myös yhteiseksi kognitiiviseksi järjestelmäksi. Tutkijat, jotka tutkivat ihmisten ja koneiden yhteistyötä, väittävätkin, että todellisen tekoälyn saavuttaminen vaatii ihmistä ja konetta, jolloin ihminen korvaa koneen heikkoudet ja toisin päin. (Peeters ym. 2021.)

Tekoälyn voi nähdä myös järjestelmänä tai sovelluksena, joka on ihmisten suunnittelema. Se voidaan nähdä järjestelmänä tai sovelluksena, joka kykenee toimimaan kompleksisen ongelman saatuaan fyysisellä tai digitaalisella tasolla. Tekoäly toimii monimutkaisen tavoitteen pohjalta havainnoiden ympäristöään tiedonkeruun kautta, tulkitsemalla strukturoitua tai strukturoimatonta tietoa sekä päättelämällä saatujen tietojen pohjalta parhaat toimenpiteet tavoitteen saavuttamiseksi. Tekoäly voi käyttää joko symbolisia sääntöjä tai oppia numeerisen mallin, ja se voi myös sopeuttaa käyttäytymistään analysoimalla, miten ympäristö vaikuttaa sen aiempiin toimiin. (Samoili, Cobo, Gómez, De Prato, Martínez-Plumed & Delipetrev 2020.)

Kun tarkastellaan tekoälyn englanninkielistä termiä Artificial Intelligence, on pelkästään ”äly” (eng. Intelligence) vaikea määrittää siten, että se kestää eri tieteenalojen vertailun. Asia kuitenkin herättää paljon keskustelua, mutta samalla myös sekaannusta. Pelkästään intelligence-sanan käyttö, antaa neljä erilaista määritystä tekoälylle. (Kok, Boers, Kosters, Van der Putten & Poel 2009.)

1. Tekoäly voidaan käsittää tietojenkäsittelytieteen alaksi, jossa se voidaan käsittää kehitykseksi, jossa kone pystyy toimimaan ihmisen tavoin ja esimerkiksi prosessoimaan, oppimaan, päättämään ja ymmärtämään itseään.
2. Koneita voidaan kehittää ottamaan haltuunsa joitain kykyjä, joita normaalisti pidetään inhimillisenä älykkyytenä, kuten oppiminen, sopeutuminen tai itsekorjaus.

3. Ihmisen älykkyyttä voidaan laajentaa tietokoneen avulla, kuten aiemmin hyödynnettiin fyysisen voiman lisäystä erilaisin mekaanisin työkaluin.
4. Tutkimusta erilaisista keinoista käyttää tietokoneita tehokkaammin parantamalla ohjelmointi tekniikoita.

Määritykset ovat myös muuttuneet aikojen saatossa, mikä johtuu nopeasta kehitystä. (Kok ym. 2009.)

Dobrev (2012) määrittää tekoälyn olevan ohjelma, joka satunnaisessa maailmassa ei pärjää huonommin kuin ihminen.

Samoili ym. (2020) ovat kuvanneet tekoälyn luokittelun kuviossa 3., joka pitää sisällään kahdeksan tekoälynluokkaa. Ensimmäinen luokka on päättely. Sillä on omat ala luokkansa, esimerkiksi automatisoitu päättely. Sillä tarkoitetaan sitä tilannetta, jossa tietokone muuntaa dataa tiedoksi.

		AI taxonomy	
		AI domain	AI subdomain
Core	Reasoning		Knowledge representation
			Automated reasoning
			Common sense reasoning
	Planning		Planning and Scheduling
			Searching
			Optimisation
	Learning		Machine learning
Communication		Natural language processing	
Perception		Computer vision	
		Audio processing	
Transversal	Integration and Interaction		Multi-agent systems
			Robotics and Automation
			Connected and Automated vehicles
	Services		AI Services
	Ethics and Philosophy		AI Ethics
		Philosophy of AI	

Kuvio 3. Tekoälyn luokittelu (Samoili ym. 2020, 11)

Toinen Samoilin ym. (2020) kuvaama luokka on suunnittelu. Se sisältää myös omat alaluokkansa, joita ovat esimerkiksi suunnittelu ja optimointi. Tällä luokalla tarkoitetaan niitä tekoälyn elementtejä, jotka pystyvät suorittamaan aktiviteettejä erilaisten strategioiden kautta. Hyvä esimerkki tästä on älykäs robotti, joka pystyy muokkaamaan toimintaansa tilanteen vaatimalla tavalla.

Oppiminen-luokassa Samoili ym. (2020) yhdistävät koneoppimisen alaluokan. Tällä tarkoitetaan kyvykkyyttä oppia, päättää ja ennustaa muutoksia ilman, että tekoälyä on tarve ohjelmoida uudelleen. Tämä luokka, kuten myös sen alaluokat ovat vahvasti edustettuja myös muissa tekoälyn luokissa. Tulee kuitenkin huomioida, että oppimista on erilaista. Tekoälyn kohdalla se koostuu valvotusta, valvomattomasta ja vahvistetusta oppimisesta, joilla jokaisella on omat erityispiirteensä.

Samoilin ym. (2020) mainitsema neljäs luokka, kommunikaatio, on tämän opinnäytetyön kannalta oleellisin luokka, sillä työ keskittyy vahvasti kommunikaatioon tekoälyn osalta. Tämän luokan aliluokkiin kuuluu NLP, jolla tarkoitetaan erilaisia kommunikointikeinoja tietokoneen ja usein ihmisen välillä. Esimerkkinä tekstin muuntaminen puheeksi tai tekstin luominen tai tekstin luokittelu.

Samoilin ym. (2020) viides luokka, havaitseminen, sisältää konenäön alaluokan ja audioprosessoinnin. Hyvä esimerkki tähän luokkaan kuuluvasta tekoälystä on ihmisen kasvojen tunnistus, mutta se voi sisältää myös erilaisten objektien tunnistusta, jota tarvitaan itseohjautuvissa autoissa.

Integraatio ja vuorovaikutus sisältää useita erilaisia kombinaatioita ja yhteistyömalleja, joissa tekoäly pystyy hyödyntämään useiden lähteiden dataa laskelmia ja aktiviteetteja toimiakseen tilanteen vaatimalla tavalla. Itseohjautuvat autot ovat hyvä esimerkki tällaisesta, jossa useiden syötteiden pohjalta pystytään tekemään päätös siitä, onko jarrutettava vai voiko auto jatkaa esimerkiksi kulkuaan eteenpäin. (Samoili ym. 2020)

Palvelut ja sen alaluokka, tekoäly palvelut viittaavat infrastruktuuriin, sovelluksiin ja alustoihin, joita tarjotaan palveluina (tai sovelluksina) esimerkiksi pilvi ympäristössä. Käytännössä tällä voidaan tarkoittaa tekoälyn tarjoamista ja sen tuottamista IaaS, PaaS, SaaS ympäristöissä. (Samoil ym. 2020)

Etiikka ja filosofia ja siihen liittyvät aiheet ovat nostaneet päätään, sekä saaneet myös ihmisten huomion, joka omalta osaltaan vaikuttaa myös valtioiden suhtautumiseen tekoälyä kohtaan. Tämän alaluokka noudattelee samaa luokitusnimeä, eli tekoäly etiikka ja tekoälyn filosofia. Tässä luokassa painotetaan erityisesti tekoälyn vaikutuksia yhteiskuntaan. (Samoili ym. 2020)

3.1 Luonnollisen kielen käsittely

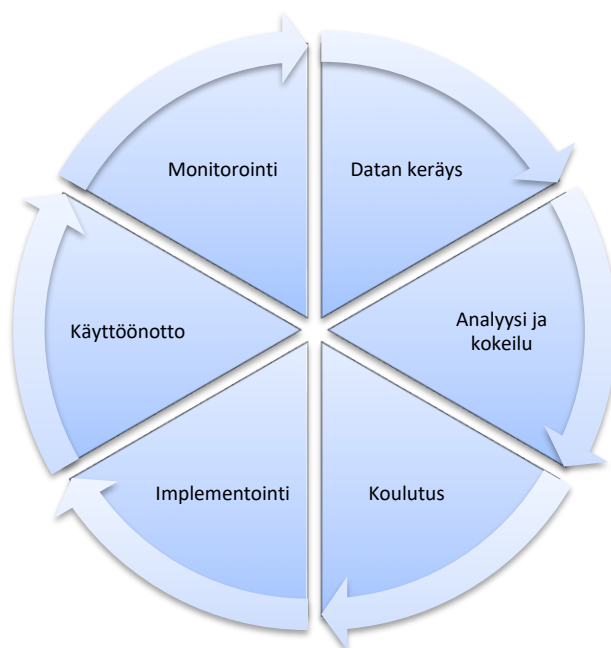
Luonnollisen kielen käsittely, Natural Language Processing (myöhemmin NLP) on tekoälyn alaluokka, jolla viitataan koneen kykyyn ymmärtää, prosessoida ja tuottaa ihmiskieltä. Syy, miksi se on osa tekoälyä ja luokitellaan tekoälyn piiriin, on se, että kielellinen tuottaminen, erityisesti teksti ja puhe, ovat iso osa ihmisen älykkyyttä. NLP on myös hyvin tutkittu aihealue ja se on tuonut myös suuria läpimurtoja tekoälyn maailmassa. On jopa ennustettu, että puheentunnistuksen tarkkuus nousee noin 95 % tarkkuudesta 99 %:iin. (Aditya, Gandhar & Vraj 2018; Hagiwara 2021)

Mitä NLP on ja mitä se ei ole? NLP voi tarkoittaa esimerkiksi yksittäisiä toimintoja, kuten käännösten toteuttamista, yhteenvedon tekemistä tai muutoin tekstin tuottamista. Yhteistä kuitenkin on se, että tarkoituksena on tuottaa hyödyllistä tietoa. Esimerkkinä voidaan pitää tilannetta, jossa käyttäjä pyrkii saamaan käännöksen lauseelle, ei yksittäiselle sanalle, jolloin kääntäjä pystyy kääntämään koko lauseen. Yksittäisen sanan kääntäminen ei vaadi varsinaisesti tekoälyä. NLP:ssä sana luonnollinen viittaa ihmisen, kielestä riippumatta, tekstin tai puheen tuottamiseen. Se voi siis tarkoittaa esimerkiksi espanjankielisen tekstin tuottamista. Kielen käsittelyllä on kuitenkin ongelmansa. Otetaan esimerkiksi suomenkielinen ”kuusi palaa”. Ilman kontekstia tiedon käsittely tässä lyhyessä ilmaisussa on lähes mahdotonta tehdä. Tarkoitetaanko subjektilla puuta, numeroa, kuutta ihmistä vai jotain muuta? Verbi lauseessa voi tarkoittaa esimerkiksi tulipaloa tai vaihtoehtoisesti takaisin tulemistä. Tämä on yksi esimerkki kielellisestä kompleksisuudesta ja semantiikasta, johon myös NLP tutkimuksessa keskitytään. (Hagiwara 2021; Kublik & Saboo 2023.)

Syväoppiminen, joka niin ikään on tekoälyn alaluokka, on ollut vaikuttamassa myös NLP:n kehittymiseen ja mahdollistanut GPT mallin luomisen. (Campesato 2021.)

NLP ominaisuuksia ja sitä hyödyntäviä sovelluksia ja työkaluja on jo käytössä. YouTube, Facebook, Twitter ja monet muut teknologiayritykset hyödyntävät NLP:n erilaisia mahdollisuuksia. Youtubessa on automaattinen tekstitys, joka muuntaa videosta kuullun puheen englanniksi, twiittejä pysytään kääntämään omalle kielelle ja Gmail tunnistaa roskapostin. NLP näkyy jo nyt käyttäjille, vaikka he eivät sitä itse ehkä ymmärrä. Lisäksi uusia käyttökohteita on tulossa jatkuvasti ja yhteiskunnan eri alat hyödyntävät ahkerasti tätä tekoälyn alaluokkaa omissa toiminnoissaan (Hagiwara 2021).

Hagiwaran (2021) mukaan NLP-sovelluksen tai järjestelmän kehittäminen on usein iteratiivinen mallin jossa toistuu kuusi eri vaihetta:



Kuvio 4. Kehityssykli NLP-sovelluksille (Mukaiillen Hagiwara 2021)

Useimmat nykyaikaiset NLP-mallit ja sovellukset perustuvat koneoppimiseen, joka tarkoittaa, että oppimisen saavuttamiseksi on oltava käytössä dataa. Usein keskustelu pohjautuu siihen, miten dataa tulisi kerätä, millaista dataa ja miten sitä käsitellään. (Hagiwara 2021.)

Kun dataa on kerätty tarpeeksi, tulee analysoida ja ajaa erilaisia kokeita. Dataa analysoidessa kannattaa etsiä signaaleja datojen välillä tai erilaisia sääntöjä, jotka toistuvat. Tehtävän onnistunut suorittaminen kannattaakin antaa henkilölle, jolla on kokemusta ja tietoa datatieteistä ja tietojenkäsittelytieteiden osa-alueita, sillä tehtävä yleensä vaatii usein tilastollisia tekniikoita. Kun analyysi on toteutettu, suoritetaan yleensä kokeita erilaisilla prototyypeillä, jotka ovat nopeita. Tällä pyritään rajaamaan mahdollisuuksia ja valitsemaan kaikista lupaavimmat kokonaisuudet. On tärkeää pystyä vastamaan, millaista ongelmaa mallilla pyritään ratkaisemaan ja millainen on ongelman ratkaisun tapa. Onko kyse tekstin luokittelusta, tekstin luomisesta tai jostain muusta, joka ratkaisee alkuperäisen ongelman. Datat keräämistä ja analysointia voidaan pitää tutkimusvaiheena. (Hagiwara 2021.)

Kun mallin koulutus aloitetaan, on yleensä selkeä ajatus NLP:n käytöstä ja ratkaisusta, kuten myös mahdollisesta sovelluksesta. Koulutusvaiheessa yleensä hyödynnetään myös tietokoneen grafiikka prosessoria normaalin prosessorin sijaan tai ulkoistetaan prosessi, koska mallin kouluttaminen voi viedä päiviä, ellei viikkoja kouluttaa. Erityisesti ne mallit, jotka perustuvat neuroverkkoihin ja sisältävät paljon dataa tai vaativat paljon dataa vaativat myös paljon prosessointia ja näin ollen myös aikaa, saavuttaakseen hyviä tuloksia. Kannattaa kuitenkin pohtia, onko järkevää kaikkia dataa kouluttaa kerralla vai voiko ensimmäisen version tehdä pienemmällä määrällä tai erilaisella mallilla. Edellä mainitun pohdinnan vuoksi onkin tärkeää, että mallin kouluttaminen pystytään toteuttamaan tarvittaessa uudelleen. (Hagiwara 2021.)

Microsoft (2021) on julkaissut MLOps-työkaluja ja prosessin edellä mainitun työn helpottamiseksi sekä erilaisten koneoppimismallien tehokkaampaa käyttöä varten.

Kun malli on valmis ja toimii hyväksyttävällä tasolla, voidaan palata perinteiseen kehittämisen prosessiin, jolla tarkoittaa tässä esimerkiksi testausta ja koodin parantelua. Mahdollinen mallin tulee myös valmistella tuotantokäyttöön ottoa varten. Tässä on kuitenkin syytä käyttää aina Continuous Integration / Continuous

Deployment-työkaluja, jolloin koneellinen käyttöönotto varmistaa, ettei inhimillisiä virheitä tapahdu. (Hagiwara 2021.)

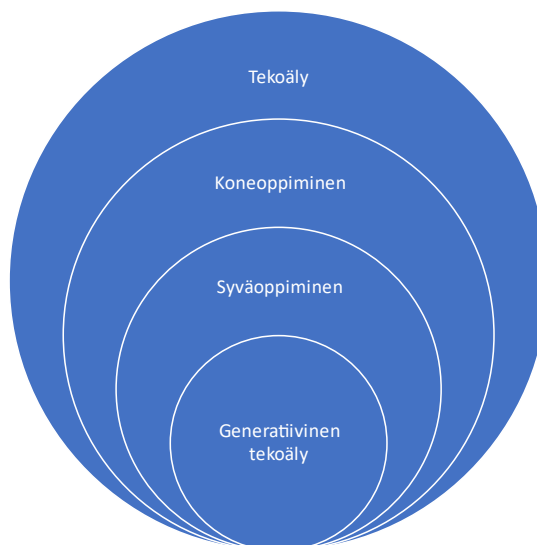
Viimeinen vaihe on yleensä monitorointi, joka on myös jatkuva vaihe, kunnes parannuksille löydetään tarpeita ja näin myös sykli lähtee alusta. Tekoälyn kohdalla monitoroinnilla tarkoitetaan hajontaa tietyissä mallin osissa ja sen ymmärtämistä. Kulkeutuuko data oikein mallissa? Tällä varmistetaan, että toteutus toimii kuten on tarkoitettu. Monitoroinnin yhteydessä on syytä pohtia, voidaanko käytössä tullutta dataa hyödyntää tulevaisuuden mallin kehityksessä. (Hagiwara 2021.)

Useat uudet NLP mallit perustuvat syväoppimisen muunnos arkkitehtuuriin (transformer architecture). Tässä opinnäytetyössä edellä mainitusta käsitteestä puhutaan muunnosarkkitehtuurina. Muunnosarkkitehtuuria käyttävät mm. BERT ja GPT. (Sudharsan 2021.)

3.2 Generatiivinen tekoäly

Generatiivisen tekoälyä voidaan pitää omana erikoisalueenaan, joka pystyy luomaan esimerkiksi tekstiä, videoita, kuvia tai musiikkia syväoppimisen avulla käyttämällä malleja, jotka on koulutettu kone oppimisen tekniikoilla. (Alto 2023.)

Generatiivinen tekoäly on siis hyvin kohdennettu alue tekoälyn sisällä (Kuvio 5.). Koneoppimisen pääasiallinen tavoite tässä kontekstissa on luoda malleja hyödyntämällä algoritmeja, joiden avulla malli voi oppia ja parantaa toimintaansa. Syväoppimisella tarkoitetaan tässä syviä malleja, joita voidaan kutsua myös neuroverkoiksi. Neuroverkkojen mallit sopivat hyvin esimerkiksi konenäköön ja sen erilaisiin sovelluksiin, mutta myös NLP:n toteuttamiseen. Koneoppimisen ja syväoppimisen osalta viitataan usein erotteleviin malleihin, jotka tekevät esimerkiksi ennusteita. Generatiivinen tekoäly ei käytä neuroverkkoja tekemällä ennusteita, vaan sen avulla voidaan luoda aiemmin mainittuja, tekstiä videoita tai musiikkia. Se ei ole erottelu malli. (Alto 2023.)



Kuvio 5. AI, ML, DL ja GAI-suhde (Mukaillen: Alto 2023.)

Nopea tekoälyn kehitys on myös tuonut paljon sovelluksia markkinoille, niin ilmaisia kuin maksullisiakin. ChatGPT, Github Copilot, DALL-E ovat levinneet tavallisten ihmisten tietoisuuteen ja käyttöön nopeasti. Kaikki edellä mainitut mallit ja sovellukset ovat generatiivisen tekoälyn malleja tai hyödyntävät generatiivisen tekoälyn mallia, jolla pystytään luomaan kuvia, tekstiä tai muuta sisältöä. Myös Microsoft on tuonut markkinoille oman Copilotin, joka pystyy käsittelemään tekstiä ja kuvia suoraan Power Point tai Excel sovelluksissa. Generatiivisella tekoälyllä on myös todettu olevan vaikutusta työntekoon. (Brynjolfsson, Li, & Raymond 2023; Stallbaumer 2023.)

Brynjolfsson ym. (2023) havaitsivat 13.8 % nousun chat-viestien käsittelyssä tuntia kohden. Edellä mainitun lisäksi generatiivisen tekoälyn hyödyntäminen kokemattomampien työntekijöiden keskuudessa nosti tehokkuutta kaikilla tuottavuus akselleilla. On kuitenkin huomattava, että samassa tutkimuksessa todettiin kehittyneempien työntekijöiden hyötyvän vähemmän tekoälystä. Tutkimuksessa hyödynnettiin GPT-mallia, joka on suuri kielimalli (Large Language Model). Lopputuloksena voitiin todeta, että generatiivisen tekoälyn hyödyntämisellä ihmisten arjessa huomattiin olevan positiivisia vaikutuksia tuottavuuden osalta.

3.3 GPT-3

GPT eli "*Generative Pre-trained Transformer*" on OpenAI tutkimuslaboratorion tuottama generatiivinen malli, joka versiosta riippuen pystyy luomaan luonnollista kieltä tekstimuodossa tai täydentämään tekstiä. Kesäkuussa 2020 julkaistiin blogi, jossa sen kuvattiin pystyvän virtuaalisesti luomaan minkä tahansa englanninkielisen tehtävän teksti sisään, teksti ulos rajapinnalla. Kyseinen versio oli nimeltään GPT-3. Malli on yleiskäyttöinen kielen prosessointimalli, jota käytännössä kuka tahansa pystyy ymmärtämään ja aloittamaan käytön nopeasti. Etuna on se, että suurta teknistä kyvykkyyttä ei tarvita, eikä ymmärrystä koodin kirjoittamisesta. Generative-sanalla viitataan mallin tyyppiin, kyseessä on siis generatiivnen tekoäly, joka kykenee luomaan tekstiä. Jotta mallia voidaan käyttää, täytyy se kouluttaa, tähän viitataan sanalla pre-trained. Transformer-sana viittaa arkkitehtuuriin. Se prosessoi tekstejä sekvensseinä sen sijaan että se käsittelisi yhtä sanaa kerrallaan. Tällöin malli saa myös selkärangan, jonka avulla se pystyy ymmärtämään sanojen suhteita toisiinsa koneellisessa maailmassa. Kyseinen arkkitehtuuri on vaikuttanut suuresti koko NLP-maailmaan. (Kinsella & Tingiris 2021; Kublik & Saboo 2023.)

Muuntaja-arkkitehtuuri kehitettiin tekoälyn suorituskyvyn parantamista varten erilaisissa muunnostehtävissä. Se keskittyy huomioimaan tiettyjä sanoja lauseissa, jotka se saa. Tämän avulla malli pääättelee, mitkä ovat oleellisia jokaisessa osassa. Esimerkiksi lauseessa "koira söi makkaran, se oli tyytyväinen" malli pystyy yhdistämään sanat "koira" ja "se". Lisäksi malli pystyy avainsanojen avulla tunnistamaan suhteita sanojen välillä, ja siten paremmin ymmärtämään muunnoksen tarpeen ja näin muodostamaan semanttisen suhteen kahden sanan välille. (Kublik & Saboo 2023.)

GPT-3 käyttää taustalla tilastollista mallia, joka laskee todennäköisyyden eri sana sekvenssien välillä. Käytännössä se siis arvaa parhaiten sopivan sanan. GPT-3 on kokonaisuudessaan kolmas versio GPT-mallista, mutta sen arkkitehtuuri ei ole juu-

rikaan muuttunut edeltäjästään, GPT-2:sta. Ainut ja ratkaiseva ero aiempaan versioon on koulutuksessa käytetyn datan määrä. GPT-3 on koulutettu hyödyntäen elektronisesti saatavissa olevia kirjoja ja tekstiä internetistä, sekä muita lähteitä sisältäen noin 57 miljardia sanaa ja 175 miljardia parametriä. Se on noin 10 kertaa suurempi kuin GPT-2. Määrä kannattaa suhteuttaa reaalimaailmaan kanssa. Ihminen puhuu, lukee, kirjoittaa ja kuulee miljardi sanaa koko elämänsä aikana, eli GPT-3 on koulutettu 57 kertaisella määrällä sanoja, joita ihminen pystyy koskaan käsittelemään. (Kinsella & Tingiris 2021.)

ChatGPT on OpenAI:n julkaisema verkkosovellus, jossa GPT-3 pohjaista mallia voi käyttää. Mallilla ja sitä käyttävällä ChatGPT:llä nähdään olevan paljo hyviä puolia, mutta myös huonoja puolia. Erityisesti huolta nostattaa erilaiset poliittiset vaikutukset, joita malli saattaa aiheuttaa. Tällainen saattaa tulla kyseeseen silloin, jos malli on itseoppiva ja saa syötteenä positiivisia sävyjä tietyn poliittisen spektrin edustamista asioista tai itse edustajista. Toinen esimerkki mahdollisista negatiivisista vaikutuksista liittyy koulutukseen ja opiskelijoiden oppimiseen, sekä opiskelijoiden tuotosten laadukkuuteen. Onkin tärkeää, että malleja käytetään oikein, eikä niiden avulla pyritä huijaamaan. Mahdolliset negatiiviset vaikutukset eivät kuitenkaan ole yksioikoisia, sillä opiskelijat voivat hyödyntää mallia esimerkiksi tiedonhaun kaltaiseen toimintaan ja jopa aiheiden ideointiin. Sen positiivisia puolia voidaan löytää useilta eri aloilta ja tieteenaloita, esimerkiksi asiakaspalvelun kohdalla virtuaalisen avun, paremman chatbotin kehittäminen. Tähän liittyen myös uuden ammattiryhmän syntyminen ei ole pois suljettua, sillä kehoitesuunnittelua ("prompt engineering") tarvitaan, jotta mallin käyttäytyminen esimerkiksi asiakas-kontekstissa on onnistunut. Mahdollisuudet ovat laajat ja myös tutkimuksen suuren määrän uuden teknologian soveltaminen aloilla on vasta alkanut. (Kalla & Smith 2023.)

3.4 Kehotesuunnittelu

Kehotesuunnittelu on uusi ja merkittävä lähestymistapa generatiivisen tekoälyn luokassa. Sen avulla pystytään toteuttamaan tehokkaita ja kustannustehokkaita tapoja käyttää erilaisia laajoja kielimalleja (Large Language Model), esimerkiksi erilaisia generatiivisia tekoälymalleja. Kehotteiden avulla pystytään opettamaan mallille uusia skenaarioita ja siksi se onkin lupaava uusi lähestymistapa ja mahdollisuus mullistaa alaa. (Wang ym. 2023b.)

Kehotteet voidaan jakaa automaattisiin ja manuaalisiin kehotteisiin. Manuaalisilla kehoitteilla tarkoitetaan yleensä ihmisten tuottamia kehoitteita, joiden avulla malli tietää, minkä tyyppiseen tietoon sen pitää keskittyä ja miten lähestyä tehtävää itessään. Manuaalisilla kehoitteilla on omat rajoitteensa. Luotettavan ja laadukkaan kehotteen toteuttaminen vaatii laajaa osaamista ja tietoa, mutta myös aikaa, sillä myös pienillä muutoksilla voi olla suuria vaikutuksia mallin toimintaan. Edellä mainittujen rajoitteiden vuoksi tutkijat ovat kehittäneet erilaisia automaattisia keinoja. Automaattiset kehotteet ovatkin yleistyneet niiden tehokkuuden vuoksi, mutta niiden tehokkuus on paljolti riippuvainen algoritmeista ja mallin representaatiosta. Yleisimmät automaattiset kehotteet ovat erilliskehote ja jatkuva kehote. Erilliskehote turvautuu ennalta määrättyihin kategorioihin luodakseen vastauksia, kun jatkuva kehote harkitsee olemassaolevan kehotteen avulla kontekstia ja pyrkii sen avulla luomaan mahdollisimman lopputuloksen. (Wang ym. 2023b.)

Generatiivisen tekoälyn osalta kehoitteella (prompt) viittaa osaan, jolla käyttäjä pystyy antamaan tietoa generatiiviselle mallille, olipa kyseessä kysymys, johon toivotaan vastausta, kehoitteella syötetään lause, sana tai kysymys, jota generatiivinen tekoäly käsittelee. ChatGPT:n kohdalla se tarkoittaa tekstiä, kun DALL-E:n kohdalla se tarkoittaa kuvia tai taidetta. Kehote on ainut keino kontrolloida mallista ulos saatavaa kieltä ja sisältöä, olettaen että käyttäjällä ei ole kykyä luoda vastavaa mallia itse. Voidaankin todeta, että kehotteen laadulla on suuri vaikutus siihen, miten tekoälyn kanssa keskustellaan tai millaisia tuloksia sillä pyritään saamaan.

Strobelt ym. (2022) toteavat myös viimeisten tutkimusten korostaneen kuinka tiettyt kehotevalinnat ovat vaikuttaneet tehtävän tarkkuuteen. Kehotetta käytettäessä kannattaakin pitää mielessä, että GPT pyrkii päättelemään seuraavaksi tulevan tekstin todennäköisyyden, jolloin ohjeilla, esimerkeillä ja oikeinkirjoituksella on lopputuloksen kannalta suuri merkitys. Ennen kehotteen käyttämistä käyttäjän olisi hyvä miettiä tarkoitusta koko mallin interaktiolle. Onko tarkoituksena kokeilla mallin toimivuutta ja käyttää sitä hauskuuden vuoksi, vai onko tarkoituksena saada mahdollisimman laadukas vastaus oikeaan kysymykseen? Kysymykseen vastaamalla käyttäjä voi päätellä, miten paljon hänen kannattaa nähdä vaivaa kehotteen ohjaamiseen. (Alto 2023; Kinsella & Tingiris 2021; Phoenix & Taylor 2024; Strobelt, Webson, Sanh, Hoover, Beyer, Pfister & Rush 2022.)

Kehotteita voidaan myös jakaa osiin: Zero-, One- ja Few-shot kehotteisiin. Näistä Zero-shot kehote on edellä mainituista yksinkertaisin ja tarjoaa ainoastaan kuvauksen tehtävästä. Se ei anna mallille juurikaan lisätietoja (Kinsella & Tingiris 2021). Ohessa esimerkki zero-shot-kehotteesta:

*Luo minulle sähköposti, joka kertoo minun olevan
pahasti sairas enkä pääse vierailemaan luennoitsijana*

One-shot-kehote tarjoaa yhden esimerkin mallille, jolla opetetaan paras tapa suorittaa sille annettu tehtävä (Kinsella & Tingiris 2021). Esimerkki tästä voisi olla:

*Anna minulle lista suomen presidenteistä
1. Sauli Niinistö*

Few-shot-kehote puolestaan tarjoaa mallille laajan määrän erilaisia esimerkkejä, joiden avulla malli pystyy suorittamaan tehtävän laadukkaasti (Kinsella & Tingiris 2021). Se voi olla vaikkapa laaja keskustelu, jossa kehotteessa esitetään kahden ihmisen välinen akateeminen keskustelu, jota malli hyödyntää suorittaakseen tehtävän. Ozdemir (2023) näkee, että erityisesti few-shot tekniikka avaa erilaisia mahdollisuuksia näiden mallien käytölle.

Mallin kohdennuksella puolestaan tarkoitetaan sen soveltuvuutta jollekin tietylle aihealueelle ja kuinka hyvin se ymmärtää sisään tulevan kehotteen. Vaikka kehotesuunnittelulla pystytään vaikuttamaan mallin tuottamaan lopputulokseen, ei se pysty käsittelemään erikoisalueita ilman tarkennusta, mallin muokkausta tai näiden kanssa yhteistyössä. (Ozdemir 2023.)

Kun kehotesuunnittelusta käydään keskustelua, on syytä muistaa sen eri muodot. Tekstistä tekstiksi -kehotesuunnittelu on vain yksi kehotesuunnittelun monista olomuodoista ja sen sukulaiskehotteet, kuten tekstistä kuvaksi ja tekstistä ääneksi täydentävät koko kehotesuunnittelu spektriä (Wang ym. 2023a).

Kehotesuunnittelulla nähdään olevan myös tiettyjä vaikutuksia yhteiskunnassa. Pelkästään OpenAI on onnistunut radikaalisti muuttamaan tapaa, jolla tekoälymallien kanssa toimitaan. Kehotesuunnittelun on povattu, osin vitsillä, olevan osuutta ohjelmointia tai keskeinen osa sitä. Kehotteiden avulla pystytään myös hyödyntämään yrityksen dataa ja siten luomaan täysin uusi näkökulma erilaisille generatiivisille malleille. (Kublic & Saboo 2023.)

3.5 Tekoälyn juridiset ja eettiset kysymykset

Kun teknologiaa tarkastellaan, on aina huomioitava lainsäädäntö, mutta myös eettiset kysymykset, sillä insinööritieteet pyrkivät usein muuttamaan maailmaa. Ailiston ym. (2018) mukaan tekoälyn näkökulmasta merkittävät eettiset ja moraaliset osa-alueet ovat:

- Moraalifilosofia, joka tutkii etiikan alan peruskäsitteitä.
- Soveltava etiikka, joka pyrkii löytämään vastauksia käytännön eettisiin ongelmiin soveltamalla erilaisia etiikan teorioita.
- Teknologian etiikka, jossa pohditaan teknologian suoria ja välillisiä vaikutuksia ihmisiin ja yhteiskuntaan
- Sodankäynnin etiikka, jossa tutkitaan myös uusien teknologioiden eettisiä ja moraalisia kysymyksiä.

Perinteisessä teknologiaeettisessä keskustelussa ihminen nähdään päätöksen teon toimijana, jolloin arviointi moraalien ja etiikan osalta toimii perinteisemmin. Tekoälyssä joudutaan kuitenkin pohtimaan myös muita kysymyksiä, esimerkiksi miten opetetaan itsenäisiä päätöksiä tekevä kone selviytymään eettisistä kysymyksistä? Kysymys onkin siis eettisistä valinnoista. Juridisissa kysymyksissä kysymys on suhteellisuusperiaatteesta päätöksiä tehdessä ja miten kone voisi oppia tekemään tätä harkintaa. Miten itseohjautuva auto toimii, kun onnettomuus on väistämätön? Entä muodostuuko tekoälylle moraalisia arvoja tai oikeuksia? (Ailisto ym. 2018, 21-23.)

Tekoälyn voi nähdä myös toteuttavan eettistä toimintaa, erityisesti tutkimuksellisesti laajan määrän dataa ymmärtävä tekoäly pystyy suoriutumaan analyyseistä huomattavasti paremmin kuin ihminen ja mahdollisesti myös objektiivisesti. Tästä huolimatta on syytä pohtia myös eettisiä varjopuolia, joita voivat olla työntekijöiden monitorointi sekä viihdealan ja mediaan kohdistuvat eettiset kysymykset, joilla voi olla myös suuria vaikutuksia yhteiskuntaan ja yksilöihin. Olkoon kyse tietoturvan puutteesta tai datan epätarkkuudesta, jonka pohjalta valtio toteuttaa päätöksiä, voivat ne vaikuttaa myös yksilön jokapäiväiseen elämään myös yhteiskunnan tasolla. (Stahl 2021, 35-39.)

Yhteiskunnalla ja lainsäädännöllä on suuri vaikutus teknologian kehittymiseen ja soveltamiseen. Kaupallinen säätely voi edistää tai rajoittaa kaupallista menestystä. Erityisesti dataa, sen omistamista ja hallintaa koskeva lainsäädännöllä on suuri vaikutus myös tekoälyn kehitykselle. Lisäksi yksityisyydensuoja ja EU:n tietoturvaasetus vaikuttavat juridisiin kysymyksiin vahvasti. Näiden pohjalta voidaan nostaa myös kysymyksiä siitä, kuka on mahdollisesti korvausvastuussa tekoälyn toteuttamista päätöksistä tai datan käytöstä. Myös turvallisuuskysymykset liittyvät olennaisesti juridisen osuuden pohdintaan, esimerkiksi datan keruun näkökulmasta. (Ailisto ym. 2018, 21-23; Hiltunen & Hiltunen 2014, 31-32.)

4 KEHITTÄMISHANKE MENETELMÄNÄ

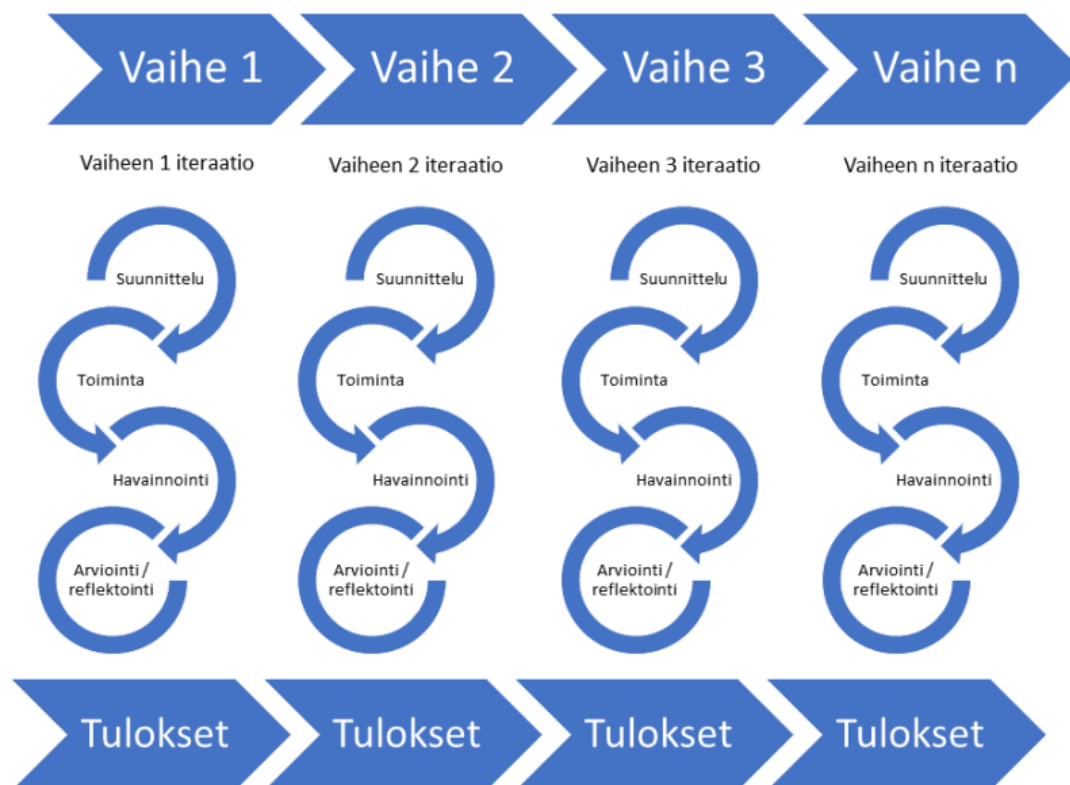
Tässä kehittämishankkeessa pyritään ratkaisemaan käytännön haasteita ja ongelmia sekä saamaan näiden ratkaisujen kautta aikaan muutos. Tässä työelämälähtöisessä kehittämishankkeessa noudatetaan toimintatutkimuksen periaatteita. Toimintatutkimuksellista lähestymistapaa voidaan kuvata myös tutkimukselliseksi kehittämistoiminnaksi, jota käytetään erityisesti ammattikorkeakoulujen viitekehystenä (Heikkinen 2018).

Heikkinen (2018) näkee toimintatutkimuksen olevan nimenä harhaanjohtava, koska se ei varsinaisesti ole tutkimusmenetelmä vaan lähempänä lähestymistapaa, jossa yhdistyy kehittämistyö ja tutkimus. Perinteistä tutkimusta ohjaa yleensä teoreettinen intressi, kun toimintatutkimuksessa ohjaava tekijä on käytännön etu. Koska toimintatutkimuksessa pyritään löytämään tietoa, joka palvelee käytännön kehittymistä, voidaan tiedon löytämiseksi käyttää erilaisia tutkimusmenetelmiä. Toimintatutkimuksessa ei tehdä tutkimusta toiminnasta ja vaan toiminnan sisällä kehittämistä varten. (Heikkinen 2018.)

Kehittämistoiminta pyrkii tuottamaan tietoa siitä, voidaanko jotain työmenetelmää pitää hyvänä. Tätä voidaan kutsua näyttöön perustuvana tietona. Se kuitenkin edellyttää näyttöä kehitettävän asian käyttökelpoisuudesta. Kun käytännön kokemuksen kautta saadaan vaikuttavuutta, voidaan puhua kokemukseen perustuvasta ammatillisesta näytöstä. Tietoa tuotetaan myös ei-tiedeperusteisesti; erityisesti tietotyöläiset tarvitsevat tietoa, joka ei ole ainoastaan tieteellistä tietoa vaan myös uutta tietoa. Tietoa syntyy myös aidoissa toimintaympäristöissä, minkä pohjalta käytännötoiminnassa ilmeneviä ongelmia ei siirretä ratkaistavaksi laboratorioihin. (Toikko & Rantanen 2009, 39-44.)

Toimintatutkimuksessa reflektiivinen ajattelu on lähtökohta kehittämiselle. Reflektoidessaan ihminen tarkastelee omia ajatuksiaan niin uskomuksien kuin kokemusten kautta. Tarkoituksena on etäännyä ja löytää uusia näkökulmia ja pohtia miksi toiminta, joka nyt esiintyy, on tietyn tyyppistä. Reflektion kautta syntyy ajan

mittaaan spiraali, jossa havainnointi, reflektointi, toiminta ja suunnittelu toistuvat. Tätä jatkuvaa sykliä kuvataan kuviossa 6. (Heikkinen 2018; Toikko & Rantanen 2009; Ojasalo ym. 2009.)



Kuvio 6. Spiraalimalli. (Mukaillen Toikko & Rantanen 2009; Ojasalo ym. 2009)

Kuvion 6. mukainen toiminta näkyy myös tässä opinnäytetyössä käytännön toiminnassa. Spiraalimalli on myös hyvin lähellä IT alalla suosittua ketterää Scrum-viitekehystä, jossa tietyn ajan sisällä suoritetaan tehtäviä sprinteissä. Tässä opinnäytetyössä hyödynnetään Scrum-viitekehystä toteutuksessa.

Scrum viitekehys on kevyt ja ketterä. Scrumissa kehityksen sykli on nimeltään sprint. Se sisältää suunnittelun (Sprint planning), päivittäisen toteutuksen suunnittelun ja kokouksen (Daily scrum), sprinttikatselmuksen (Sprint review) ja sprintin retrospektiivin (Schwaber & Sutherland 2021). Spiraalimallin ja Scrumin yhtymä-

kohtia kuvataan taulukossa 1. Tässä opinnäytetyössä sprintti on määritetty kuu-kauden mittaiseksi. Yhden sprintin aikana on tarkoitus saavuttaa sille määritetyt tavoitteet.

Taulukko 1. Spiraalimallin ja Scrumin yhtenäisyydet (Mukaillen Schwaber & Sutherland 2021; Toikko & Rantanen 2009, 67)

Malli	Spiraalimalli	Scrum
Suunnittelu vaihe	Suunnittelu	Sprint Planning
Toiminnan vaihe	Toiminta	Daily Scrum
Havaintovaihe	Havainnointi	Sprint review
Reflektiivisyys	Arviointi / Reflektointi	Retrospective
Malli	Vaiheistettu, toistuva	Vaiheistettu, toistuva
Selkeät erot	Tutkimuksellinen, näyttöä odotetaan	Tavoitteena luoda arvoa ja ratkaista ongelma

Suunnitteluvaiheessa hanketta kirkastetaan ja tavoitteena on asettaa suunnitelma. Sekä scrumissa että spiraalimallissa suunnittelu on dokumentoitu. Niillä on selkeät tavoitteet, toimijat ja monia muita yhtenäisyyksiä. Tässä vaiheessa on yleisesti tiedossa, että kaikkia asioita tai tehtäviä ei pystytä täydellisesti suunnittelemaan pitkällä aikavälillä, vaan asioita tarkennetaan. On myös huomioitava, että molemmissa malleissa tiedostetaan tietämättömyys siihen, mikä toimii ja mikä ei. (Schwaber & Sutherland 2021; Toikko & Rantanen 2009; Salonen, K. 2013.)

Toiminnallisessa vaiheessa erilaiset toimijat toimivat yhtenäisen tavoitteen saavuttamiseksi, mallista riippumatta. Scrumissa toimintaa kuvataan yksityiskohtaisesti, kun taas spiraalimallissa kuvataan yleisesti toiminnan olevan yhteistoimintaa erilaisten toimijoiden kanssa. Spiraalimalli ei luonteensa vuoksi ota kantaa tarkasti

esimerkiksi dokumentointi tapoihin, kun taas Scrum kuvaa ja ohjaa myös dokumentaatiota ja muuta toimintaan sen ketteryyden arvojen kautta. (Schwaber & Sutherland 2021; Toikko & Rantanen 2009; Salonen, K. 2013.)

Sekä scrumissa että spiraalimallissa havainnointi on olennainen osa. Scrumin sprint review keskittyy tarkastelemaan suorituksen lopputulosta ja pohtii muutoksia tulevaisuutta varten. Scrum antaa myös tarkempaa ohjeistusta kyseisen toiminnan toteuttamiseen verrattuna spiraalimalliin. (Schwaber & Sutherland 2021; Toikko & Rantanen 2009; Salonen, K. 2013.)

Sekä spiraalimalli että Scrum nostavat esille reflektoinnin tärkeyden ja objektiivisuuden. Spiraalimalli korostaa tutkimuksellisuutta ja erityisesti eettisiä kysymyksiä liittyen arvioinnin ja reflektoinnin luotettavuuteen, kun scrum puolestaan puhuu avoimuudesta. Molemmissa kuitenkin korostetaan objektiivisen lopputuloksen saavuttamista, spiraalimallissa tutkimuksen periaatteiden kautta, scrumissa puolestaan arvojen ja psykologisen turvallisuuden kautta. (Schwaber & Sutherland 2021; Toikko & Rantanen 2009; Salonen, K. 2013.)

5 KEHITTÄMISHANKKEEN TOTEUTUS

Tässä luvussa keskitytään kuvaamaan työn toteutumista sen eri vaiheissa. Työn tulokset ja pohdinta kuvataan myöhemmissä vaiheissa. Tässä kehityshankkeessa on hyödynnetty Scrum-viitekehystä soveltaen, mutta pääpainona on toteuttaa työelämälähtöinen kehittämissanke, joka noudattaa toimintatutkimuksen periaatteita.

5.1 Hankkeen suunnittelu

Hankkeen suunnittelu lähti liikkeelle tarpeiden arvioinnilla ja määrittelyllä. Hankkeen tarpeet on kerätty organisaation omien palaute- ja kehitysjärjestelmien kautta, minkä jälkeen niitä on käsitelty kehitysryhmässä. Hanke koostuu useasta, toisistaan erillään olevasta, mutta toisiaan tukevasta kokonaisuudesta.



Kuvio 7. Hankkeen rakenne.

Hankkeen toteuttamisessa on kehitystarpeisiin perehtynyt ryhmä. Hankeosuuk- sissa on useita henkilöitä, jotka toimivat tarvittaessa myös hankkeiden välillä, toi-

siaan tukien. Arkkitehtuurisissa tehtävissä olevat henkilöt liikkuvat ja tukevat kaikkia hankkeiden osia tavoitteiden saavuttamisessa. Työn tekijä toteuttaa ja suunnittelee arkkitehtuurin ja toteutuksen yhteistyössä työryhmän kanssa. Työryhmä koostuu erilaisista kompetensseista, joista jokaisella on vahva teknologinen osaaminen. Työn tekijän tehtävänä on toteuttaa generatiivinen tekoälysovellus, joka kykenee hyödyntämään organisaation omaa dataa.

Tässä työssä esiteltävälle hankeosuudelle on asetettu oma suunnitelma, jota kuvataan kuviossa 8.

Aikataulu (Suunnitelma)



Kuvio 8. Aikataulusuunnitelma

Hankkeen organisaatio koostuu viidestä henkilöistä, jotka tukevat toisiaan yli hankerajojen. Hankkeeseen osallistuneiden roolit on kuvattu taulukossa 2.

Taulukko 2. Hankkeen henkilöstö

Henkilö	Rooli
CTO	Product owner
Arkkitehti A	Arkkitehti / Kehittäjä
Arkkitehti B	Arkkitehti / Kehittäjä
Kehittäjä C	Kehittäjä
Kehittäjä D	Kehittäjä
Opinnäytetyön tekijä	Arkkitehti / Kehittäjä

5.1.1 Tarpeen määrittely

Ennen hankkeen aloitusta tarpeita on kerätty useista eri lähteistä. Tuoteomistaja hallitsee ja käsittelee tarpeet parhaaksi näkemällään tavalla, joka tukee organisaation tavoitteita. Taulukossa 3 on kuvattu hankeosuuden tärkeimmät tarpeet ja niiden kategoriat. Samaisessa taulukossa tarpeet on muokattu hyväksymiskriteereinä ensimmäiselle vaiheelle. Käyttötarkoituksena tekoälypohjaiselle generatiiviselle sovellukselle on tukea organisaation service desk työntekijöitä saamaan tietoa jo ratkaistuista tehtävistä ja kyetä etsimään tietoa, miten tehtävät on ratkaistu.

Taulukko 3. Tarvemäärittely ja hyväksymiskriteerit

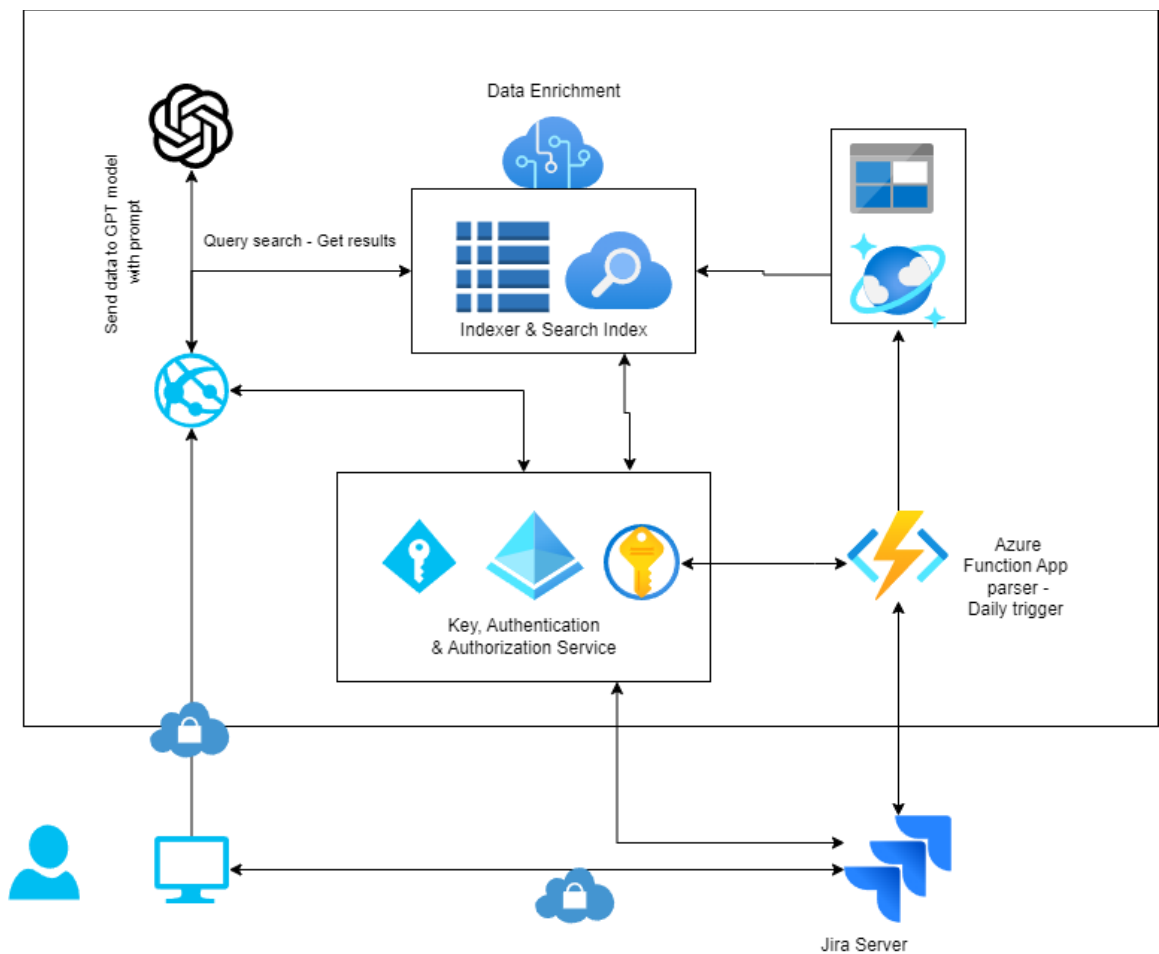
Kategoria	Hyväksymiskriteeri
Käyttöliittymä	<ul style="list-style-type: none"> - Käyttäjän on helppo käyttää sovellusta. - Käyttäjä pystyy kirjoittamaan chat viestejä. - Tekoäly kykenee vastaamaan kysymyksiin tai lähetettyyn viestiin.
Saavutettavuus	<ul style="list-style-type: none"> - Käyttäjä pystyy käyttämään sovellusta web-se-laimella puhelimesta ja tietokoneelta. - Sovellus on oltava saavutettavissa 24/7/365.
Turvallisuus	<ul style="list-style-type: none"> - Sovellusta ei pääse käyttämään muut kuin organi-saation käyttäjät. - Tietoon eivät pääse käsiksi kuin ne, joilla on tie-donsaantiin oikeus tai lupa. - Tietoturvallinen tapa käsitellä dataa.
Arkkitehtuuri	<ul style="list-style-type: none"> - Arkkitehtuurissa hyödynnetään mahdollisimman paljon pilviympäristöä. - Arkkitehtuuri rakentuu Microsoft Azure ympäri-stöön ja komponentteihin. - Arkkitehtuuria voidaan helposti muokata tarvitta-essa.
Data	<ul style="list-style-type: none"> - Tiedon käsittely on jatkuvaa ja tieto päivittyy vä-hintään kerran päivässä. - Tieto päivittyy automaattisesti tai sitä voidaan päivittää tasaisin väliajoin. - Tietoa pystytään käsittelemään, suomen ja eng-lanninkielisistä lähteistä. - Dataa hyödynnetään ainoastaan organisaation omista lähteistä.
Keskustelu	<ul style="list-style-type: none"> - Keskustelua kyetään käymään englannin kielellä. - Keskustelu kykenee antamaan viiteen käyttäjälle, mistä tieto on peräisin.

5.1.2 Arkkitehtuuri

Arkkitehtuuri ja siihen liittyvät kysymykset aiheuttivat laajaa pohdintaa koko kehitysryhmän piirissä. Ensimmäisen vaiheen lopullinen malli saatiin mallinnettua käytettävän datan analysoinnin jälkeen. Dataa kerätään Jira järjestelmästä, jossa tietoa erilaisista Service Desk -toiminnoista on jo olemassa. Tieto ei suurella todennäköisyydellä pysty vastamaan kaikkiin kysymyksiin, miten ongelma on ratkaistu.

Arkkitehtuurin suunnittelu aloitettiin pohtimalla jo olemassa olevia ratkaisuja ja Microsoftin toteuttamia ratkaisuja. Tämän pohjalta havaittiin, että Microsoft on julkaissut MIT-lisenssöidyn chat-käyttöliittymän, jolla pystytään käyttämään LLM-mallia Azuressa. Se on myös helppo julkaista ja se sisältää lähes valmiiksi toteutetun autorisoinnin ja autentikaation itse sovelluksessa. Toinen ongelmakohta oli itse tekoälyn käyttäminen. On yleisesti tiedossa, että Microsoft tarjoaa Azure-palveluympäristössä tekoälyn liittyviä palveluita, mutta organisaation oman datan hyödyntäminen tuottaa omia haasteita. Ratkaisuksi pohdittiin Azure Cognitive search palvelua, jonka kautta voidaan indeksoida olemassa oleva data, joka on kerätty Jirasta.

Edellä mainittujen ongelmakohtien selvittäminen arkkitehtuurisessa kontekstissa helpotti koko arkkitehtuurin suunnittelua, jonka pohjalta päädyttiin Kuvion 9 mukaiseen arkkitehtuuriin.



Kuvio 9. Ratkaisun arkkitehtuuri

Arkkitehtuurissa hyödynnetään VPN-verkkoa, johon pääsee ainoastaan organisaation käyttäjätunnus-salasana yhdistelmällä. Kyseinen autentikaatio hyödyntää kaksivaiheista tunnistautumista, jonka Azure Active Directory tarjoaa. Jira itsessään sijaitsee julkisessa verkossa, mutta se on niin ikään suojattu kaksivaiheisella tunnistautumisella. Arkkitehtuuriin lisättiin Azure function app, joka kykenee aikalaukaisimen kautta siirtämään Jira dataa Cosmos DB NoSQL tietokantaan sekä käsittelemään datan ennalta määritellyn mallin mukaiseksi.

Arkkitehtuurin yksi tärkeimmistä osista on Azure Cognitive search ja indekseri, sekä indeksi, joka kykenee rikastamaan olemassa olevaa dataa tekoälyn avulla. Verkkosovelluspohjainen sovellus on Azure Web app. GPT mallin käytetään GPT-3.5-turbo -versiota.

5.2 Toteutus

Käytännön toteutus aloitettiin pilviarkkitehtuurin tärkeimpien komponenttien osalta. Aloituksen jälkeen saatiin tietoon uusi akuutti tarve, jonka toteuttaminen tukee organisaatiota paremmin. Uutena tarpeena oli se, että tekoälyn olisi pystyttävä käsittelemään organisaation Microsoft Dynamics D365-lisenssitietoja käsitteleviä dokumentteja ja tarvittaessa vastaamaan näihin liittyviin kysymyksiin. Arkkitehtuuriin tämä muutos ei aiheuttanut muutoksia, sillä blob storage oli jo suunniteltu otettavaksi käyttöön.

Koska kyseessä on Scrum-mallinen kehitys, jossa kehittäjillä on suuri kyky vaikuttaa toteutukseen ja sprintin sisältöön, työn tekijän päätöksellä tavoite lisättiin tehtävä listaan ja Azure-funktion toteuttaminen siirrettiin seuraavaan vaiheeseen. Muutoin tehtävälista pysyi samana koko toteutuksen ajan.

Toteutuksen aikana todettiin useita pienempiä ongelmia ja haasteita, sillä moni Microsoftin pilvipalvelun komponenteista olivat preview -vaiheessa, eli ei vielä julkisesti saatavilla, joten muutokset aiheuttivat pieniä muutoksia myös koodiin. Lähes kaikki ongelmat saatiin lopulta ratkaistua ja sovellus toimitettua testattavaksi ennen aikataulun mukaista tavoitepäivämäärää.

Testaus toteutettiin pääosin hankeryhmän sisällä, mutta palautetta kerättiin käyttäjiltä, kun ensimmäinen versio saatiin julkaistua pilviympäristöön. Palaute kerättiin lyhyellä lomakkeella ja avoimella Slack-kanavalla, jonne pystyttiin raportoimaan löydöksiä ja esittämään jatkokehitykselle toiveita.

5.2.1 Käytettävä data ja datamalli

Toteutuksen tekninen implementointi aloitettiin datan analysoinnilla. Analysoinnin kohteena olevasta datasta ensimmäisessä vaiheessa oli noin 65 000 Jira-tehtävää. Tällä tehtiin alustava rajausta perustuen tehtävän luokitteluun. Luokittelun avaimeksi valittiin infra, joka toteuttaa organisaatiossa IT-infrastruktuuriin liittyviä

tehtäviä. Tämän jälkeen aineistoa analysoitiin tarkemmin, minkä pohjalta päädyttiin tekemään päivämäärä rajausta ja määrällinen rajausta. Hankkeessa päädyttiin hyödyntämään 500 viimeiseksi suljettua tehtävää, mutta osa näistä sisältänyt ei käytettävää tietoa tai niiden tietosisältö oli hyvin rajallinen. Lopulta lopullinen ensimmäisessä vaiheessa käytettävien tehtävien määrä oli 473.

Hankkeen ensimmäisessä vaiheessa pyrittiin toteuttamaan mahdollisimman yksinkertainen datamalli, jota voidaan myöhemmissä vaiheissa parantaa, kun tietoa ja kokemuksia käytöstä saadaan riittävästi. Koska Azure Function App päätettiin siirtää seuraavaan kehitysvaiheeseen, vietiin json muotoinen dokumentti Cosmos DB tietokantaan käsin. Siirron jälkeen tietokanta sisälsi kaikki 473 tehtävää datamallin mukaisessa formaatissa. Kuviossa 10 on esitetty esimerkki datan sisällöstä.

```
{
  "id": "123456",
  "self": "API rajapinta osoite",
  "key": "ABC-123",
  "summary": "Tulostin",
  "description": "ongelmia tulostimen kanssa",
  "comments": [
    "moi, mikä ongelma?",
    "ei mikään, testailen vain"
  ],
  "url": "linkki jira tehtävään",
  "rid": "Rivin id",
  "translated_text": "",
  "translated_summary": ""
}
```

Kuvio 10. Datamalli

Datamallissa huomioitiin myös mahdollinen tarve kääntää teksti, sillä toteutuksen aikana päätettiin kääntää suomenkieliset tekstit englannin kielelle.

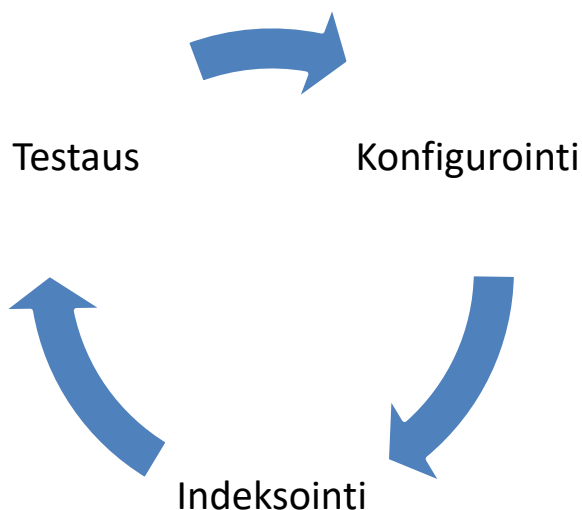
5.2.2 Tekninen toteutus

Tekninen osuus aloitettiin Azure funktion kehittämisellä, kunnes tarve muutokselle esitettiin hankkeelle. Kehityksen aikana onnistuttiin kuitenkin tekemään itse

toteutus pitkälle ja tästä pystyttiin hyödyntämään funktion käsittely osuutta käsittelemään dataa, joka viedään Cosmos tietokantaan. Azure Funktion lähdekoodi ajettiin manuaalisesti tietokoneella, ja se loi json tiedoston, joka vietiin käsin tietokantaan. Muut funktion kannalta oleelliset toteutukset jäivät odottamaan seuraavaa vaihetta.

Toteutusta jatkettiin Azure Cognitive Search -palvelussa, johon kuuluivat indekseri, indeksi, sekä datan rikastamiseen sopivia erilaisia tekoälypalveluita, jotka voitiin konfiguroida indeksoinnin yhteyteen. Ennen tätä asetettiin palveluun datalähteeksi aiemmin määritetty Cosmos DB, joka sisälsi jira tehtävien dataa.

Toteutuksen kannalta suurin osa käytetystä ajasta käytettiin indeksoinnin, datan ja indekserin toiminnan parantamiseen, sekä indekserin tekoälytoimintojen kohdistamiseen. Tässä noudatettiin syklistä mallia, jossa useaan kertaan kierrettiin konfiguraatio–indeksointi–testaus -syklissä. Kuviossa 11. kuvataan kehityksen aikana tapahtunutta sykliä.

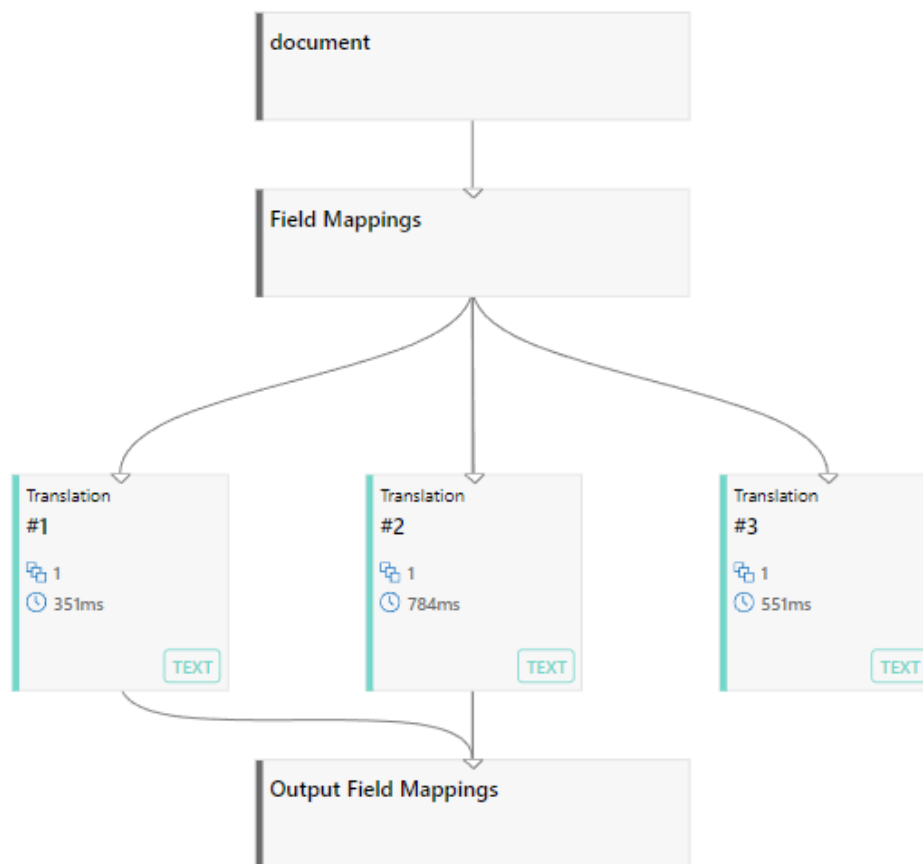


Kuvio 11. Kehityksen sisällä tapahtuva sykli

Konfiguroinnissa toteutettiin ja testattiin erilaisia variaatioita datan ja azuren suhteen. Tällä oli tarkoituksena saada mahdollisimman hyvä ja laadukas lopputulos

datan ja datan rikastamisen kannalta. Rikastamisella tarkoitetaan tässä Azure Cognitive searchin tarjoamia tekoälypalveluita, joita voidaan käyttää indeksoinnin yhteydessä. Tällaisia ovat esimerkiksi käännökset, paikan tai organisaation nimien erottaminen, dokumenttien erottaminen tai vaikka optisten kirjainten tunnistaminen. Tässä opinnäytetyössä käytettiin sekä OCR-toimintoja, että käännöksiä indeksoinnin yhteydessä. Indeksoinnin yhteydessä hyödynnettävät tekoälytoiminnot helpottavat arkkitehtuurin monimutkaisuutta, mutta nopeuttavat myös kehittämistä. Toisena vaihtoehtona toteutukselle olisi ollut toteuttaa käännökset Azure funktion yhteydessä hyödyntämällä Azure translator palvelua. Tämä osaltaan myös vaikutti siihen, miksi Azure funktiota ei nähty tärkeänä komponenttina ensimmäisessä vaiheessa.

Indeksoinnin jälkeen tarkistettiin indeksointi ja arvioitiin käännöksiä. Usein käännöksiä datamalli saattoi olla epäotollinen ja siksi uudelleen indeksointia tarvittiin, tai ajoittain muutoksien yhteydessä myös datamalli koki pieniä muutoksia. Ajoittain myös indekseri törmäsi virheisiin, jotka johtuivat joko datasta tai väärästä konfiguraatiosta. Väärin indeksointien ja väärän mallisen datan ilmentymistä analysoitiin Azure Cognitive searchin debug-sessiolla, jonka avulla saatiin kuvaa siitä mikä mahdollisesti oli mennyt vikaan. Kuviossa 12 kuvataan, kuinka debuggerin avulla saatiin näkyviin, miksi käännös ei näkynyt indeksissä lainkaan.



Kuvio 12. Azure Session Debugger

Kun Cognitive searchin indeksi saavutti sille asetetut tavoitteet ja sisälsi kaikki vaadittavat elementit, testattiin indeksiä ja datan saatavuutta indeksin sisällä. Haku itsessään toimi moitteetta lähes jokaisessa tapauksessa, kunhan indeksoinnin yhteydessä asetettu kenttien ominaisuudet oikein. Taulukossa 4 kuvataan asetukset kentille.

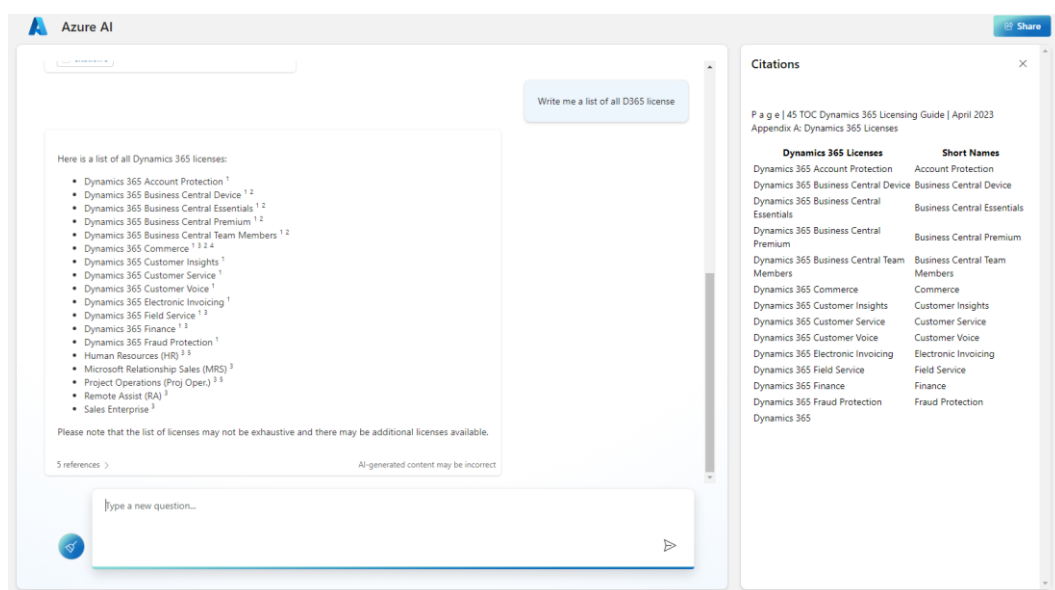
Taulukko 4. Indeksoinnin kenttäkonfiguraatiot

<i>Kenttä</i>	Retrievable	Filterable	Sortable	Facetable	Searchable
<i>Id</i>	X	X		X	X
<i>Self</i>	X				X
<i>Key</i>	X	X	X	X	X
<i>Summary</i>	X				X
<i>Description</i>	X				X
<i>Comments [ARRAY]</i>					
<i>[ARRAY] string</i>	X				X
<i>url</i>	X				X
<i>Rid</i>	X	X	X	X	X
<i>Translated_text</i>	X				X
<i>Translated_summary</i>	X				X

Kun indeksoinnissa saavutettiin sille asetetut tavoitteet hakujen kannalta, keski-tyttiin myös käyttöliittymän julkaisuun. Käyttöliittymälle asetettiin omat vaatimukset, mutta myös tietoturvaan liittyvät tekijät täytyi huomioida toteutuksessa. Toteutuksessa hyödynnettiin Microsoftin avointa lähdekoodia. Myöhemmin toteutuksen yhteydessä havaittiin, että Azure OpenAI playground kykenee myös julkaisemaan sovelluksen suoraan Azure Webapp palveluna. Koska kyseinen sovellus ei ole vielä tuotantokäytössä, päädyttiin julkaisu tekemään suoraan Azure openAI playgroundin kautta, sillä se on nopea ja helppo tapa saattaa sovellus testattavaksi.

Käyttöliittymän sisäänkirjautuminen tapahtuu käyttämällä organisaation sähköpostiosoitetta ja salasanaa, jonka jälkeen tunnistuksen toinen vaihe alkaa. Kun käyttäjä kirjautuu sisään, avautuu hänelle kuvion 13 mukainen käyttöliittymä.

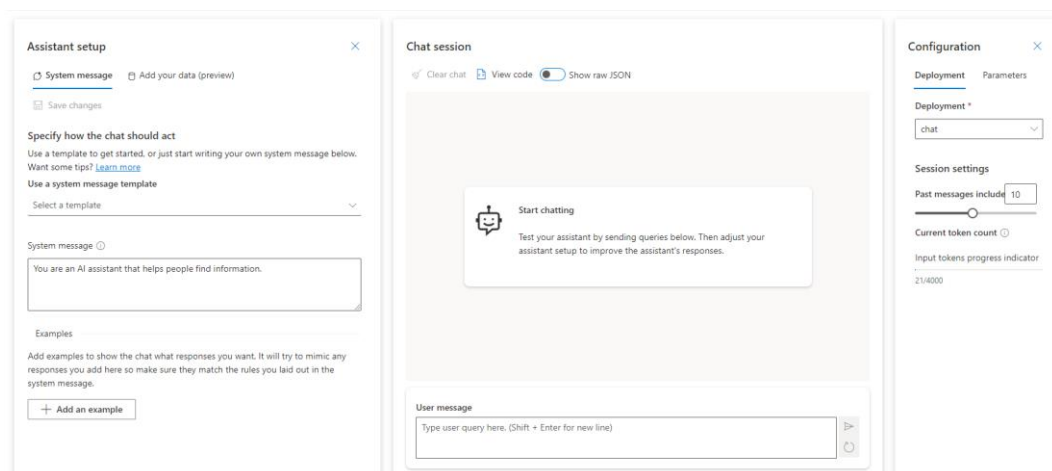
Käyttöliittymä on yksinkertainen kehotemallinen ikkuna, jossa pystytään esittämään kysymyksiä ja saamaan vastauksia kysymyksiin. Oikealla puolella ilmenee mahdolliset viitteet, jotka kertovat mihin tieto perustuu. Keskustelu ikkunassa ei siis näy pelkästään vastausta käyttäjän kysymyksiin, vaan se kykenee myös kertomaan haettavan tiedon lähteen, joka on äärimmäisen tärkeä arvioitaessa luotavuutta. Käyttöliittymä toimi myös lopullisena testauspaikkana, kun vaatimuskriteerejä testattiin sovelluksessa.



Kuvio 13. Käyttöliittymä

5.2.3 Testaus

Testaus oli syklin viimeinen vaihe ja myös siinä testattiin eri alueita arkkitehtuurissa. Indeksoinnin osalta tehtiin hakuja ja arvioitiin hakujen onnistumista, mutta viimeinen testaus ennen varsinaista käyttäjien testausta oli Azure Playgroundissa tapahtuva testaus. Tässä ympäristössä pystyttiin myös määrittämään esimerkiksi erilaisia kehoitteita chatille. Se ei kuitenkaan sovellu laajempaan kehoitesuunnitteluun. Yleensä tässä vaiheessa yhdistettiin myös aiemmin toteutettu indeksi ja määritettiin käyttöliittymän kautta asetukset, jotta voitiin arvioida, onko kyseinen kokonaisuus käyttäjä testaukseen sopiva. Kuvio 14 antaa yleiskuvan playground ympäristöstä.



Kuvio 14. Azure openAI playground

Playground-ympäristö helpottaa testausta ja nopeuttaa kehitystä, mutta laajempaa kehotesuunnittelua varten on julkaistava kokonaan uusi sovellus.

6 TULOKSET

6.1 Tulosten arviointi

Tässä luvussa keskitytään opinnäytetyön lopputuloksiin. Työn lopullisena tulokseksi toteutettiin yksinkertainen käyttöliittymä hyödyntämällä Microsoftin pohjaa, joka pystyy hakemaan tietoa olemassa olevista Jira-tehtävistä, joiden tieto oli siirretty tietokantaan. Datana se käyttää ensimmäisessä vaiheessa noin 473 tehtävää, jotka on viimeksi suljettu. Edellä mainitun lisäksi toteutettiin Microsoft Dynamics D365 lisenssi dokumentteihin liittyvä hakukone, joka kykenee hyödyntämään tietoa suoraan Dynamics dokumenteista ja vastamaan käyttäjän kysymyksiin, jotka liittyvät dokumenteissa mainittuihin tietoihin.

Lopputulosten arviointi perustuu hanketta toteuttavan ryhmän omaan arviointiin tavoitteiden saavuttamisesta, sekä testauksia tehneiden henkilöiden antamiin arvioihin.

Opinnäytetyön tarkoituksena oli selvittää:

1. Pystytäänkö hankkeessa luomaan pilvipalvelu, jossa käyttäjä pystyy esittämään kysymyksiä GPT mallille ja saamaan vastauksia

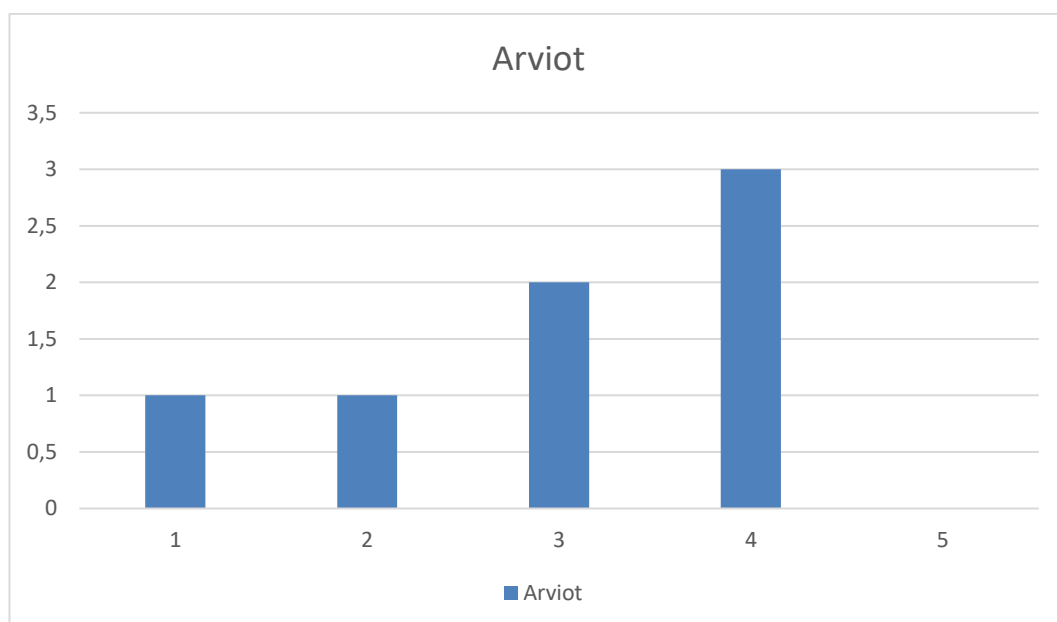
Hankkeessa luotiin pilvipalvelu, johon liitettiin Microsoftin toteuttama käyttöliittymä, joka kykenee vastaan ottamaan kysymyksiä ja antamaan niihin vastauksia, mutta vastauksien laatu vaihtelee suuresti.

2. Pystyykö GPT hyödyntämään organisaation dataa vastauksia antaessaan ja näin luomaan arvoa käyttäjälle?

Palvelu pystyy hyödyntämään organisaation omaa dataa, vaarantamatta sen julkisuutta, mutta työssä ei oteta kantaa käyttäjän aiheuttamaan tietoturva riskiin. Tällä viitataan esimerkiksi tiedon käsittelyyn. Se pystyy luomaan arvoa käyttäjälleen, mikäli data on olemassa ja käsitelty oikein, mutta nykyinen toteutus vaatii

kehitystä erityisesti Service Desk-tehtävien käsittelyn osalta. Datan määrää palveluksessa on syytä kasvattaa ja sen antamia vastauksia uudelleen arvioitava seuraavassa vaiheessa, jotta voidaan varmistua vastausten laadukkuudesta.

Edellä mainituista osuuksista käyttäjät testasivat hakukoneen ensimmäisenä. Testauksessa se täytti kaikki sille asetetut vaatimukset, mutta siinä on myös selkeästi parannuksen kohteita. Palautetta kerättiin testaajilta yleisarvosanan osalta, josta se sai keskiarvioksi 3.13. Hakukoneen testaajille annettiin tehtäväksi kysyä hakukoneelta neuvoa D365-lisenssikysymyksiin.



Kuvio 15. Testaajien yleisarvio

Keskusteluissa useat henkilö kuvasivat käyttöliittymän olevan helppokäyttöinen ja toimiva. Vastaukset, joita henkilöt saivat, vaihtelivat suuresti, sillä myös kysymyksissä oli laajaa vaihtelua. Osa kysymyksistä vaati laajaa ymmärrystä lisensointimalleista, kun taas osa kysymyksistä olivat perustietoa vaativia kysymyksiä. Ensimmäisen vaiheen toteutus hakukoneen muodossa ei siis vielä tue laajempaa käyttöä, jossa käyttäjät saattaisivat kysyä vaikeampia, laajempaa ymmärrystä vaativia kysymyksiä. Samaan lopputulokseen tuli myös hankeryhmän henkilöstö.

Työlle asetetut tavoitteet täyttyivät, mutta toteutuksessa on useita kehityskoh- teita. Tämä opinnäytetyö koskee ainoastaan hankkeen ensimmäistä vaihetta. Hanke jatkuu ja toteutuksia kehitetään saatujen kokemusten perusteella.

6.2 Kehitysehdotukset

Dynamics-lisenssitietojen hakukone ratkaisu jätetään testaukseen, sillä se toimii hyvänä ponnistuslautana uusille kehittäjille, jotka kiinnostuvat kehittämään gene- ratiivista tekoälyä eteenpäin organisaatiossa. Tätä voidaan myös kehittää eteen- päin lisäämällä dataa esimerkiksi käyttöohjeista ja muista dokumenteista, sekä pa- rantamalla hakutulosten luokittelua.

Jira tehtäviä käsittelevän osan toteuttamisessa hankeryhmä päätti, ettei se vie to- teutusta vielä käyttäjättestausvaiheeseen vaan toteutusta jatketaan ja paranne- taan. Hankeryhmän toteuttamien testauksien aikana se ei kyennyt antamaan tar- peeksi laadukkaita vastauksia kysymyksiin, jotka liittyivät samaisiin aiheisiin, jotka indeksistä löytyivät. Arvioinnin yhteydessä todettiin, että hakutoimintoja pitää pa- rantaa ja myös vektori haku lisätä kyseiseen toteutukseen. Hankeryhmä arvioi, että se tukee toteutukselle asetettuja tavoitteita paremmin.

6.2.1 Data

Data ja sen laadukkuus on selkeä kehityksen kohde, mutta data ja sen käsittely tuottaa myös tulevaisuutta ajatellen laajasti kehityskohteita. Pohdintaan jää myös se, onko Microsoftin uudella Microsoft Fabricilla mahdollisesti tulevaisuudessa rooli datan käsittelyssä. Microsoft Fabric pitää sisällään laajan määrän työkaluja, joten sen hyötyjä täytyy hankeryhmän arvioida tarkkaan. Eräs kysymys, johon han- keryhmän täytynee ottaa kantaa, on se, onko yhteensopivuus oikealla tasolla LLM- mallien kanssa, kun se hyödyntää organisaation omaa dataa, ja miten se sopii ark- kitehtuuriin. Toinen kysymys liittyy myös siihen, missä kontekstissa on syytä poh- tia Fabricin käyttöönottoa.

Toinen oleellinen kysymys datan laadun lisäksi on datan määrä. Tässä työssä hyödynnettiin 473:a kohdetta, mutta malli pystyi vain osittain vastaamaan kysymyksiin. Datan laadun merkitys korostui erityisesti tässä kontekstissa, mutta toisaalta myös kehoitteiden merkitys saattaa vaikuttaa suuresti vastauksiin. Kun Jira tehtävistä piti etsiä yhtenäisyyksiä, oli lopputulos aavistuksen verran parempi, joskin osuma tarkkuus oli edelleen alhainen.

Mikäli Jira-tehtävät tarjoaisivat selkeästi ratkaisun esitettyyn ongelmaan, olisi haun osumatarkkuuden parantaminen todennäköisesti huomattavasti helpompaa. Osumatarkkuuden parantamiseksi ehdotetaan, että seuraavassa vaiheessa käytettävässä datassa on ongelma-ratkaisu -rakenne. Mikäli tieto halutaan eriyttää myös käytännössä, vaatii se laajempaa muutosta ja mahdollisesti myös toimintatavan muutoksen.

Datan määrää on myös syytä kasvattaa ja hyödyntää tietyn kategorian dataa, jolloin testaukset voidaan osoittaa tietyn tyyppisille kysymyksille, esimerkiksi infrastruktuuriin liittyviksi.

Edellä mainituista syistä automaatio ei vielä ole ajankohtainen ja tästä syystä automaattinen indeksointi uuden datan suhteen nähdään toistaiseksi tarpeettomana. Automaation asettaminen vaatii sen, että usean eri kategorian data aineiston vastaukset ovat parempia.

Data-aineiston muoto on myös yksi oleellinen vaikuttava tekijä. Dynamics-lisensitietojen hakukone on muodostettu pdf-dokumenteista, ja tämä on voi olla myös datan struktuurin näkökulmasta yksi syy sille, miksi malli pystyy antamaan parempia vastauksia kysymyksiin. Onkin syytä selvittää, saadaanko tulevaisuudessakin parempia vastauksia pdf pohjaisista dokumenteista. Tällaisissa tapauksissa on kuitenkin syytä huomioida mallin kyvykyys indeksoida tietty määrä tietoa dokumenteista ja pohtia sivuttamista myös dokumenttien käsittelylle.

Mikäli data-aineistojen määrää aiotaan lisätä, on syytä muistaa ja pohtia myös ratkaisuja niihin tilanteisiin, jossa dataa koskevat erilaiset juridiset kysymykset. Tällä viitataan esimerkiksi tapauksiin, joissa datan omistaa joku toinen tai se on muutoin salassa pidettävää.

6.2.2 Käyttöliittymä

Käyttöliittymän osalta mahdollinen kehityskohde on valmiiden kehoitteiden tarjoaminen käyttäjille. Tämä voidaan toteuttaa helposti luomalla testattuja ja toimivia kehoitteita käyttäjälle, jotka ovat saatavissa napin painalluksena. Toinen, niin ikään kehoitteisiin liittyvä mahdollinen ehdotus on esittää ehdotuksia käyttäjille erilaisista kehoitteista perustuen heidän aiempiin keskusteluihinsa. Tämä toteutus vaatii huomattavasti suurempaa analysointia toteutuksesta.

Mielenkiintoisen potentiaalın tarjoaa myös mahdollisuus vaihtaa datalähdettä. Mikäli indeksit on asetettu valmiiksi, voisi käytännössä yksittäinen käyttöliittymä toimia kokonaisen organisaation datan hyödyntämisessä, samoin kuin Microsoftin copilot. Samalla on ratkaistava, miten rajoitetaan käyttäjien pääsyä tiettyihin aineistoihin.

Laki saavutettavuudesta on myös olennaista, erityisesti niissä tilanteissa, joissa laki velvoittaa saavutettavuuden noudattamista. Käyttöliittymälle ei ole tehty saavutettavuusarviota.

Koska käyttöliittymä on yksinkertainen ja rakennettu react-viitekehyykseen, voisi käyttöliittymä olla mahdollista myös asettaa uudelleen käytettäväksi, chatbot-tyyliseksi ratkaisuksi verkkosivuille. Tällainen kuitenkin vaatii myös automaatiota infrastruktuurin osalta, mutta se voidaan ratkaista esimerkiksi Terraform IaC:lla. Terraform on infrastructure as a code -työkalu, jolla voidaan pystyttämään infrastruktuuri helposti koodilla lähes kaikkiin suosituimpiin pilviympäristöihin, kuten Azure, AWS ja Google Cloud (Terraform 2023). Tällä hetkellä IaC-käyttö ei kuitenkaan ole

mahdollista, sillä tässä opinnäytetyössä on käytetty komponentteja, jotka ovat vielä pre-view-tilassa eivätkä ne siten ole yleisesti saatavilla.

6.2.3 Järjestelmäkokonaisuus ja käyttökohteet

Tässä työssä toteutettu kokonaisuus hyödyntää Microsoftin pilvipalveluita, mikä on myös organisaation strateginen valinta, mutta se ei poista mahdollisuutta pohdita ratkaisun asettamista osittain tai kokonaan myös muihin ympäristöihin. Erilaisia datalähteitä voisikin olla myös nykytoteutuksen ulkopuolella ja integroinnilla voidaan yhdistää erilaisia datalähteitä, kuten tässä tapauksessa Jira. Kun puhutaan useista datalähteistä, Microsoft Fabric voi olla mahdollinen ratkaisu ongelman ratkaisemiseksi. Järjestelmäkokonaisuuden komponenttien ja osien valinta ja erilaiset vaihtoehdot asettavatkin kysymyksiä tulevaisuutta ajatellen. Voisiko Microsoft Fabric toimia tulevaisuudessa kokonaisvaltaisesti datan hallinnan ratkaisuna?

Tietoturvan kehittäminen on oleellista erityisesti silloin, kun tekoälypohjaisella ratkaisulla on pääsy organisaation dataan. Vaikka tietojen käyttöä voidaan rajata Azure AD:n avulla, on varmistuttava myös siitä, että tieto, joka tietokantaan tai muihin järjestelmän osiin tulee, on varmistettu siten, ettei se sisällä salassa pidettävää materiaalia. Tämän takia hanke suositteliekin automaatioiden ja muiden toteutusten osalta myös DevSecOps-näkökulman hyödyntämistä.

Tässä työssä toteutettu kokonaisuus soveltuu tiettyyn käyttötarkoitukseen, jonka vuoksi hankkeen seuraavissa vaiheissa on syytä paneutua muihin käyttötapauksiin ja tarvittaessa pohtia arkkitehtuuria kokonaisuudessa. Nykyisellään ratkaisu ei ole suoraan yhteensopiva esimerkiksi tuottamaan vastauksia asiakkaille erilaisiin tietoteknisiin ongelmiin, vaan soveltuu ainoastaan asiantuntija organisaation sisäisen tiedon etsintään, hakukoneen tapaan.

Jos pohditaan muita käyttötapauksia tai käyttökohteita, voisi esimerkiksi ammatikorkeakoulut hyötyä samankaltaisesta ratkaisusta, jossa opinnäytetöiden parhaimmisto sekä muuta oleellista tieteellistä aineistoa olisi indeksoitu. Tämän

avulla sekä opettajat että opiskelijat pystyisivät hyödyntämään viimeisintä tietoa. Etuna tässä ratkaisussa on erityisesti se, että ratkaisu kykenee näyttämään myös lähteen ja siten lähteen arviointi on mahdollista. Käyttöliittymän ja Azure AD:n avulla järjestelmässä voitaisiin käytännössä rajata myös hakujen tuloksia opiskelijan tai opettajan mukaan. Toinen esimerkki samaisessa kontekstissa voisi olla ratkaisu, joka tarjoaa tietoa opiskelijoille ohjeita, keinoja ja erilaisia neuvoja korkeakoulun ohjeistuksiin perustuen.

7 POHDINTA

Tiedon määrä organisaatioissa digitalisaation myötä laajenee ja tiedon hyödyntämisen tärkeys organisaation kehittämisessä korostuu. Tiedon on oltava saatavissa, jotta sitä voidaan hyödyntää. Tehtävän aikana kävi selväksi, että laaja määrä dataa voi olla organisaatiolle tärkeää, erityisesti silloin kun se sisältää ratkaisuja mahdollisesti olemassa oleviin ongelmiin. Toisaalta se voi myös tarjota vastauksia kysymyksiin, joihin ei vielä tiedetä vastauksia.

Pelkkä data ei kuitenkaan ole välttämättä ihmiselle ymmärrettävää, usein siksi että se on tietokannoissa tai muuten mahdottomassa muodossa. Se voi myös olla dokumenteissa, joiden lukemiseen käytetään paljon aikaa. Tekoäly, erityisesti generatiivinen tekoäly, pystyykin olemaan avuksi tilanteissa, joissa tietoa pitää käsitellä nopeasti tai ihmisten saada vastaus kysymyksiin, joita ei perinteiset hakukoneet tarjoa. Näen, että hakukone tyyppinen ratkaisu helpottaa organisaatioita tulevaisuudessa, sekä nopeuttaa työntekijöiden toimintaa arkisissa askareissa.

Tässä kehityshakkeessa tarkoituksena oli toteuttaa ensimmäinen vaihe, jossa luodaan kyvykkyys tekoälyn hyödyntämiselle tilanteissa, jossa organisaation omaa dataa halutaan käyttää. Tulevaisuuden kehityskulkuja tulee arvioida tarkkaan, sillä niillä saattaa olla suuria vaikutuksia myös arkkitehtuurin näkökulmasta. Toinen erityinen kysymys liittyy datan laatuun, joka on olennainen kysymys minkä tahansa tekoälymallin käytössä. Onko data tarpeeksi laadukasta? Tällä hetkellä laatu vaihtelee datan osalta suuresti.

Opinnäytetyön tekeminen oli tekijälle haastavaa erityisesti teknisestä näkökulmasta, mutta se oli oletettavaa jo aiheen valinnan yhteydessä, sillä se sisälsi useita kysymyksiä, joihin ei aiheen valinnan yhteydessä vielä ollut vastauksia. Tässä kehityshankkeessa käytettiin toiminnallisuuksia, palveluita ja komponentteja, jotka eivät ole vielä kaikille saatavilla ja ovat edelleen kehityksessä. Tämä oli tietoinen valinta, joka teki työn toteuttamisesta mielenkiintoisen ja haastavan mutta myös ajankohtaisen.

Kehityshanke ei kehittänyt pelkästään organisaation toimintaa, vaan myös työn tekijän tiedot ja taidot voidaan todeta ottaneen suuren loikan, mitä tulee teko-älyyn ja generatiivisiin malleihin, mutta myös pilviympäristöön ja arkkitehtuuriin.

Kun tarkastellaan työn eettisyyttä, on huomioitava, että tutkimukseen liittyvät eettiset kysymykset pysyvät usein samoina, riippumatta siitä, onko kyse yhteiskunnan tai ihmistenvälisestä vuorovaikutuksesta ja siihen liittyvistä eettisistä säännöistä. Kehittämistyö on inhimillistä toimintaa, mikä tarkoittaa, että kehittämiss-hankeeseen osallistuvilla tahoilla on myös omat rajoitteensa. (Ojasalo, Moilanen & Ritalahti 2009, 48-49; Heikkinen & Syrjäjä 2007, 147-148.)

LÄHTEET

Aditya, J., Gandhar K., Vraj S. 2018. Natural Language Processing. International Journal of Computer Sciences and Engineering, 6(1), 161-167.

Ailisto, H., Helaakoski, H., Dufva, M., & Tuikka, T. 2017. Tuottoa ja tehokkuutta Suomeen tekoälyllä. Helsinki. VTT.

Ailisto, H., Heikkilä, E., Helaakoski, H., Neuvonen, A., & Seppälä, T. (2018). Tekoälyn kokonaiskuva ja osaamiskartoitus. Helsinki. Valtioneuvoston kanslia.

Aljanabi, M. (2023). ChatGPT: Future directions and open possibilities. Mesopotamian journal of Cybersecurity, 2023, 16-17.

Alto, V. 2023. Modern Generative AI with ChatGPT and OpenAI Models: Leverage the Capabilities of OpenAI's LLM for Productivity and Innovation with GPT3 and GPT4. Packt Publishing.

Brynjolfsson, E., Li, D., & Raymond, L. R. 2023. Generative AI at work (No. w31161). National Bureau of Economic Research.

Buchanan, B. G. 2005. A (very) brief history of artificial intelligence. Ai Magazine, 26(4), 53-53.

Camposato, O. 2021. Natural Language Processing Fundamentals for Developers. Stylus Publishing.

Dobrev, D. 2012. A definition of artificial intelligence. arXiv preprint arXiv:1210.1568.

Hagiwara, M. 2021. Real-World Natural Language Processing. Manning Publications.

Heikkinen, H. L. T. 2018. Ikkuinoita Tutkimus metodeihin 1. Metodien valinta ja aineistonkeruu: virikkeitä aloittelevalla tutkijalla. Toim. Valli, R. Jyväskylä. PS-Kustannus.

Heikkinen, H. L. T., & Syrjälä, L. 2006. Tutkimuksen arviointi. Teoksessa HLT Heikkinen, E. Rovio & L. Syrjälä (toim.) Toiminnasta tietoon. Toimintatutkimuksen menetelmät ja lähestymistavat. Helsinki. Kansanvalistusseura.

Hill-Yardin, E. L., Hutchinson, M. R., Laycock, R., & Spencer, S. J. 2023. A Chat (GPT) about the future of scientific publishing. Brain Behav Immun, 110, 152-154.

Hiltunen, E. & Hiltunen, K. 2014. Teknoelämää 2035. Miten teknologia muuttaa tulevaisuuttamme?. Helsinki. Talentum.

Kalla, D. & Smith, N. 2023. Study and Analysis of Chat GPT and its Impact on Different Fields of Study. *International Journal of Innovative Science and Research Technology*, 8(3).

Kinsella, B. & Tingiris, S. 2021. *Exploring GPT-3*. Packt Publishing.

Kok, J. N., Boers, E. J., Kusters, W. A., Van der Putten, P., & Poel, M. 2009. Artificial intelligence: definition, trends, techniques, and cases. *Artificial intelligence*, 1, 270-299.

Kublik, S. & Saboo, S. 2023. *Gpt-3: The Ultimate Guide to Building NLP Products with OpenAI API*. Birmingham: Packt Publishing, Limited.

Microsoft. 2021. *MLOps with Azure Machine Learning*. Viitattu 5.8.2023. <https://azure.microsoft.com/en-us/resources/mlops-with-azureml/>

Microsoft. 2023a. *What is Azure OpenAI Service?* Viitattu 2.8.2023. <https://learn.microsoft.com/en-us/azure/ai-services/openai/overview>

Microsoft. 2023b. *Microsoft and OpenAI extend partnership*. Viitattu 2.8.2023. <https://blogs.microsoft.com/blog/2023/01/23/microsoftandopenaiextendpartnership/>

Ojasalo, K., Moilanen, T. & Ritalahti, J. 2009. *Kehittämistyön menetelmät, uudenlaista osaamista liiketoimintaan*. Helsinki. WSOYpro Oy.

Ozdemir, S. 2023. *Quick Start Guide to Large Language Models: Strategies and Best Practices for using ChatGPT and Other LLMs*. Addison-Wesley Professional.

Peeters, M. M., van Diggelen, J., Van Den Bosch, K., Bronkhorst, A., Neerincx, M. A., Schraagen, J. M., & Raaijmakers, S. (2021). Hybrid collective intelligence in a human–AI society. *AI & society*, 36, 217-238. Viitattu 2.8.2023. https://www.karlvandenbosch.nl/documents/2020_Peeters_etal_AI&S_Hybrid_collective_intelligence_in_a_human%E2%80%93AI_society.pdf

Phoenix, J. & Taylor, M. 2024. *Prompt Engineerin for Generative AI*. Early release. O'reilly Media inc.

Russell, S. & Norvig, P. 2014. *Artificial intelligence – A Modern Approach*. Prentice Hall.

Salonen, K. 2013. *Näkökulmia tutkimukselliseen ja toiminnalliseen opinnäytetyöhön*. Opas opiskelijoille, opettajille ja TKI-henkilöstölle. Turku. Turun ammattikorkeakoulu.

Samoili, S., Cobo, M. L., Gómez, E., De Prato, G., Martínez-Plumed, F., & Delipetrev, B. 2020. *AI Watch. Defining Artificial Intelligence. Towards an operational*

definition and taxonomy of artificial intelligence. Luxemburg. European Commission.

Schwaber, K., & Sutherland, J. 2021. The Scrum Guide. 2020. Accessed April.

Siukonen, T. & Neittaanmäki, P. 2019. Mitä tulisi tietää tekoälystä. Jyväskylä. Docendo.

Stahl, B. C. 2021. Artificial intelligence for a better future: an ecosystem perspective on the ethics of AI and emerging digital technologies. Leicester. Springer Nature.

Stallbaumer, C. 2023. Introducing Microsoft 365 Copilot – A whole new way to work. Microsoft. Viitattu 7.8.2023. <https://www.microsoft.com/en-us/microsoft-365/blog/2023/03/16/introducing-microsoft-365-copilot-a-whole-new-way-to-work/>

Strobelt, H., Webson, A., Sanh, V., Hoover, B., Beyer, J., Pfister, H., & Rush, A. M. (2022). Interactive and visual prompt engineering for ad-hoc task adaptation with large language models. *IEEE transactions on visualization and computer graphics*, 29(1), 1146-1156.

Sudharsan, R. 2021. Getting Started with Google BERT: Build and train state-of-the-art natural language processing models using BERT. Packt Publishing, Limited.

Sun, F. 2022. ChatGPT, the start of a new era.

Terraform. 2023. What is terraform? Viitattu 24.9.2023. <https://developer.hashicorp.com/terraform/intro>

Toikko, T. & Rantanen, T. 2009. Tutkimuksellinen kehittämistoiminta. Tampere. Tampereen yliopistopaino Oy.

Wang, J., Liu, Z., Zhao, L., Wu, Z., Ma, C., Yu, S., Dai, H., Yang, Q., Liu, Y., Zhang, S., Shi, E., Pan, Y., Zhang, T., Zhu, D., Li, X., Jian, X., Ge, B., Yuan, Y., Shen, D., Liu, T., & Zhang, S. 2023. Review of large vision models and visual prompt engineering. arXiv. preprint arXiv:2307.00855.

Wang, J., Shi, E., Yu, S., Wu, Z., Ma, C., Dai, H., Yang, Q., Kang, Y., Wu., Hu, H., Yue, C., Zhang, H., Liu, Y., Li, X., Ge, B., Zhu, D., Yuan, Y., Shen, D., Liu, T. & Zhang, S. 2023. Prompt engineering for healthcare: Methodologies and applications. arXiv preprint arXiv:2304.14670.