



Krista Ulmanen

Kustomoidun GPT-chatbotin toteutus ja julkaisu

Metropolia Ammattikorkeakoulu

Insinööri (AMK)

Tieto- ja viestintäteknikka

Insinöörityö

13.5.2024

Tiivistelmä

Tekijä: Krista Ulmanen
Otsikko: Kustomoidun GPT-chatbotin toteutus ja julkaisu
Sivumäärä: 36 sivua
Aika: 13.5.2024

Tutkinto: Insinööri (AMK)
Tutkinto-ohjelma: Tieto- ja viestintätekniikka
Ammatillinen pääaine: Ohjelmistotuotanto
Ohjaaja: Osaamisaluejohtaja Janne Salonen

Insinööriyön aiheena oli toteuttaa GPT-pohjaisen chatbotin kustomointi käyttäen OpenAI:n GPT Builder -työkalua.

Työn tarkoituksena oli selvittää, miten GPT Builder toimii, miten kustomoitu chatbot on mahdollista yhdistää ulkopuoliseen palveluun API-ohjelmointirajapinnan kautta sekä miten valmiin chatbotin julkaisu OpenAI:n kauppapaikalle tapahtuu.

Opinnäytetyön kirjallisuuskatsauksessa hyödynnettiin aihetta käsittelevää kirjallisuutta sekä tieteellisiä artikkeleja ja verkkolähteitä. Niiden pohjalta työssä käydään läpi keskustelemaan tekoälyn kehittymisen kannalta olennainen tietoperusta generatiivisen tekoälyn, koneoppimisen, laajojen kielimallien sekä luonnollisen kielen käsittelyn osalta.

Työn lopputuloksena syntyi käyttäjän apukokiksi räätälöity chatbot, joka pystyy ehdottamaan käyttäjälle terveellisiä reseptejä, luomaan kauppalistan ja noutamaan ravintoainetietoja THL:n Fineli-tietokannasta hyödyntäen palvelun API-rajapintaa.

Työn jatkokehitys vaatii käyttäjäpalautteen keräämistä, jonka avulla chatbotin hienosäätöä voidaan jatkaa ja kohdistaa paremmin vastaamaan käyttäjien tarpeita.

Avainsanat: generatiivinen tekoäly, GPT, chatbot, kehoitesuunnittelu, luonnollisen kielen käsittely

Tämän opinnäytetyön alkuperä on tarkastettu Turnitin Originality Check -ohjelmalla.

Abstract

Author: Krista Ulmanen
Title: Customizing and publishing a GPT chatbot
Number of Pages: 36 pages
Date: 13 May 2024

Degree: Bachelor of Engineering
Degree Programme: Information and Communication Technology
Professional Major: Software Engineering
Supervisor: Janne Salonen, Head of School in ICT

The subject of the engineering thesis was to customize a GPT-based chatbot using OpenAI's GPT Builder tool.

The purpose of the work was to understand how the GPT Builder works, how a customized chatbot can be connected to an external service via an API interface, and how to publish the finished chatbot on OpenAI's marketplace.

In the literature review of the thesis, relevant literature, scientific articles, and online sources were utilized. Based on these, the thesis explores the essential knowledge base for the development of generative AI in terms of machine learning, large language models and natural language processing.

As a result of the work, a user-assistant chatbot was created, tailored to suggest healthy recipes, create a shopping list, and retrieve nutrient data from the THL's Fineli database using the service's API interface.

Further development of the work requires the collection of user feedback, which will help in fine-tuning the chatbot and better targeting it to meet user needs.

Keywords: Generative AI, GPT, Chatbot, Prompt engineering, Natural language processing

Sisällys

Lyhenteet

1	Johdanto	1
2	Generatiivinen tekoäly	2
2.1	Koneoppiminen	2
2.2	Syväoppiminen ja neuroverkot	4
2.2.1	Siirto-oppiminen	5
2.2.2	Takaisinkytketty neuroverkko	6
2.2.3	Generatiiviset kilpailevat verkostot	7
2.2.4	Variaatioautoenkooderit	8
2.2.5	Transformer-mallit	9
2.3	Generatiivisen tekoälyn sovellukset	10
2.4	Generatiivisen tekoälyn haasteet ja tulevaisuus	12
3	Laajat kielimallit	13
3.1	Luonnollisen kielen käsittely	14
3.2	Keskusteleva tekoäly	15
3.2.1	OpenAI:n ChatGPT	16
3.2.2	Metan Llama-mallit	17
3.2.3	Googlen LaMDA ja PaLM	17
3.3	Multimodaaliset mallit	19
3.4	Kehotesuunnittelu	20
4	GPT:n kustomointi	21
4.1	GPT-Builder-työkalu ja toiminnallisuudet	21
4.1.1	Knowledge-toiminto	25
4.1.2	Actions-toiminto ja API-rajapinnat	26
4.1.3	GPT:n antamien vastausten pituus ja Tokenit	29
4.2	GPT:n julkaisu OpenAI Storeen	29
4.2.1	GPT:n näkyvyyden määrittäminen	30
4.2.2	Julkaistun GPT:n hallinta ja käytön seuraaminen	31
4.3	Projektissa esiin tulleet ongelmat ja jatkokehitys	31
5	Yhteenveto	32

Lyhenteet

- AI: *Artificial Intelligence*. Tekoäly on tietokonejärjestelmien suorittamaa ihmisen älyllisten prosessien simulointia, kuten päättely, oppiminen ja havainnointi.
- GenAI: *Generative Artificial Intelligence*. Generatiivinen tekoäly on tekoälyn alaluokka, joka keskittyy uuden sisällön tai datan luomiseen.
- GPT: *Generative Pre-trained Transformer*. Generatiivinen esiopetettu muuntaja on transformer-arkkitehtuurin perustuva tekoälymalli, joka on esikoulutettu suurilla tekstimäärillä.
- NLP: *Natural Language Processing*. Luonnollisen kielen käsittely on tekoälyn alue, joka keskittyy ihmiskielen ymmärtämiseen ja tuottamiseen.
- ML: *Machine Learning*. Koneoppiminen käsittää algoritmien ja tilastollisten mallien kehittämisen, joiden avulla tietokoneet voivat suorittaa tehtäviä ilman eksplisiittisiä ohjeita.
- DL: *Deep Learning*. Syväoppiminen hyödyntää monikerroksisia neuroverkkoja datan eri tekijöiden analysointiin, kun matkitaan ihmisaivojen toimintaa.
- RNN: *Recurrent Neural Network*. Takaisinkytketty neuroverkko on neuroverkkotyyppi, jossa solmujen väliset yhteydet muodostavat suunnatun graafin ajallisen sekvenssin mukaisesti, mikä mahdollistaa sekvenssien käsittelyn käyttämällä sen sisäistä tilaa (muistia).
- LSTM: *Long Short-Term Memory*. Pitkä lyhytaikainen muisti on RNN-tyyppi, joka kykenee oppimaan pitkäaikaisia riippuvuuksia ja on tehokas estämään katoavan gradientin ongelmaa, joka voi esiintyä perinteisissä RNN-verkoissa.

- GAN: *Generative Adversarial Network*. Generatiivinen kilpaileva verkosto on kahdesta toisiaan vastaan kilpailevasta neuroverkosta koostuva koneoppimismalli.
- VAE: *Variational Autoencoder*. Variaatioautoenkooderi on neuroverkko, jota käytetään ohjaamattomaan oppimiseen monimutkaisten datan kuvioiden osalta, käyttäen Bayesilaisen päättelyn periaatteita.
- API: *Application Programming Interface*. Ohjelmointirajapinta on sovelusten rakentamiseen tarkoitettujen sääntöjen ja työkalujen joukko, jota käytetään mahdollistamaan eri ohjelmien kommunikointi keskenään.

1 Johdanto

Keskusteleavan tekoälyn kehitys on mahdollistanut monipuolisemman vuorovai-
kutuksen ihmisten ja koneiden välillä. Chatbotit voivat olla yksinkertaisia, sään-
töihin perustuvia sovelluksia, jotka reagoivat tiettyihin avainsanoihin tai lausei-
siin ennalta määrätyllä tavalla. Ne voivat myös olla monimutkaisempia järjestel-
miä, jotka hyödyntävät syväoppimista ymmärtääkseen paremmin kontekstia op-
piakseen käyttäjän aiemmasta vuorovaikutuksesta ja tuottaakseen luonnolli-
sempia ja asiaankuuluvampia vastauksia.

Tämän opinnäytetyön tarkoituksena oli muokata kustomoitu versio OpenAI:n
ChatGPT-mallista, joka on suunnattu erityisesti käyttäjän avustajaksi keittiössä.
Keskeisenä tavoitteena oli luoda chatbot, joka tarjoaa käyttäjille terveellisiä koti-
ruokareseptejä sekä niihin liittyvät ostoslistat ja yksityiskohtaiset ravitsemustie-
dot. Mallin muokkaaminen tapahtui OpenAI:n GPT Builder -työkalun avulla,
jonka avulla ChatGPT-malleja voi muokata vastaamaan tiettyjä käyttötarpeita ja
toiminnallisuuksia. Opinnäytetyön aihe on rajattu GPT:n kustomointiin ja julkai-
suun. Chatbotin laajempi toiminnallinen testaus, käyttäjäpalautteen kerääminen
ja sen perusteella tapahtuva hienosäätö on rajattu pois.

Opinnäytetyössä käydään läpi myös generatiivisen tekoälyn keskeisiä konsep-
teja ja sovelluksia, jotka ovat merkittäviä nykypäivän tekoälytutkimuksessa ja
kehityksessä. Generatiivinen tekoäly (Generative AI) on tekoälymallien luokka,
joka pyrkii tuottamaan sisältöä, kuten tekstiä, kuvia, ääntä tai videota. Toisin
kuin perinteiset diskriminatiiviset mallit, jotka pyrkivät ennustamaan vastauksia
tiettyjen syötteiden perusteella, generatiiviset mallit kykenevät luomaan koko-
naan uutta sisältöä.

OpenAI:n kehittämä ChatGPT on edistynyt keskusteleava generatiivinen tekoäly,
joka perustuu transformer-arkkitehtuuriin. Se on suunniteltu ymmärtämään ja
tuottamaan luonnollista kieltä, joka mahdollistaa monipuoliset ja kontekstuaali-
set keskustelut.

Luonnollisen kielen käsittely on tieteenala, joka keskittyy ihmiskielen ymmärtämiseen ja sen prosessointiin tekoälyjärjestelmissä. Kehotesuunnittelu, eli mallin kyky reagoida ja vastata tiettyihin prompteihin eli syötteisiin, on olennainen osa keskusteleavan tekoälymallin kehitystä. Hyvin suunniteltu kehote voi ohjata tekoälyä tuottamaan sisällöllisesti tarkempia ja käyttäjää paremmin hyödyttäviä vastauksia.

Tekoälypohjaisten sovellusten nopea kehittyminen on jo käytännössä muuttanut sen, miten dataa haetaan, sovelletaan ja luodaan. Ne tuovat mukanaan luovuutta ja tehostavat toimintoja useilla eri toimialoilla. Tekoälyn käytössä on kuitenkin otettava huomioon monia eettisiä kysymyksiä, kuten tietosuoja, tekijänoikeudet ja tuotetun sisällön aitouden varmistaminen.

2 Generatiivinen tekoäly

Generatiivisella tekoälyllä (Generative Artificial Intelligence, GenAI) tarkoitetaan tekoälyjärjestelmiä, jotka kykenevät tuottamaan uutta dataa, kuten tekstiä, kuvia, ääntä, musiikkia tai videoita, joita ei ollut olemassa ennen kyseisen järjestelmän käyttöä. Generatiivisen tekoälyn avulla voidaan luoda uutta sisältöä, joka on mahdollisimman lähellä alkuperäistä ihmisen tuottamaa sisältöä tai järjestelmän kouluttamiseen käytettyä dataa sitä kuitenkaan suoraan kopioimatta. (Foster 2023.)

Generatiivisen tekoälyn kehitys perustuu koneoppimisen ja syväoppimisen menetelmiin, kuten generatiivisiin kilpaileviin verkostoihin (GAN), variaatioautoenkoodereihin (VAE) ja uudempiin esiopetettuihin transformer-malleihin (GPT).

2.1 Koneoppiminen

Koneoppiminen (Machine Learning, ML) on tekoälyn ala, joka keskittyy algoritmien ja mallien kehittämiseen, jotka pystyvät oppimaan datasta ilman ohjelmointia tiettyjä tehtäviä varten. Koneoppimismallien tavoitteena on tehdä ennusteita tai päätelmiä datasta.

Tärkeimpiä koneoppimisen sovelluskohteita ovat tietokonenäkö, luonnollisen kielen käsittely (NLP), puheen- ja äänenkäsittely sekä tietokonegrafiikka. 2020-luku on tuonut eri alat lähemmäs toisiaan, ja samoja koneoppimismenetelmiä voidaan hyödyntää ristiin niin edellä mainituilla aloilla kuin esimerkiksi robotiikan kehittämisessä. (Kämäräinen 2023: 12.)

Koneoppimismallit ovat oleellisia tekoälyn kehityksen kannalta. Niitä hyödynnetään monissa tekoälyn alemman ja korkeamman tason toiminnoissa. Alemman tason toimintoja ovat muun muassa tietyn tiedon hakeminen suuresta datamäärästä tai kuvien luokittelu eri kategorioihin. Ylemmän tason toimintoja ovat tekoälyn käytöksen (toimintojen) mukauttaminen ympäristöön sopivaksi ja sen oppiminen aiemmista toiminnoista palautejärjestelmän avulla. (Jung 2022: 10–11.)

Vaikka tekoälysovelluksissa onkin saavutettu suuria kehityksellisiä harppauksia muun muassa kuvien tuotannossa (Stable Diffusion, Midjourney, Dall-E) ja käyttäjän kanssa keskustelemissa sovelluksissa kuten OpenAI:n ChatGPT:ssä, toistaiseksi koneoppimismallit eivät täysin yllä ihmisälykkyyden tasolle. (Kämäräinen 2023: 10.)

Ohjatulla oppimisella (Supervised Learning, SL) tarkoitetaan koneoppimisen mallia, jossa algoritmi oppii opetusdatasta pyrkien yhdistämään sille syötetyt tiedot (input) oikeaan tulokseen (output). Malli tekee ennusteita tai päätöksiä sille syötettyjen tietojen perusteella ja sitä korjataan, kun sen ennusteet ovat vääriä. Ohjattua oppimista käytetään yleisesti luokittelu- ja regressioanalyysin tehtävissä. (Kämäräinen 2023: 94.)

Ohjatussa oppimisessa koneoppimismallien koulutukseen käytetään merkittyä dataa (labeled data). Merkitty data voi olla esimerkiksi kuvia eri esineistä, joihin on merkitty, mitä kuva esittää. Todellisuudessa suuri osa saatavilla olevasta datasta ei ole merkittyä, ja työ pitää tehdä joko manuaalisesti tai käyttää toista tekoälymallia merkitsemään raakadata. Datan merkitsemiseen voi kulua huomattavan paljon aikaa, varsinkin jos tietojoukot ovat suuria. (Awan 2023.)

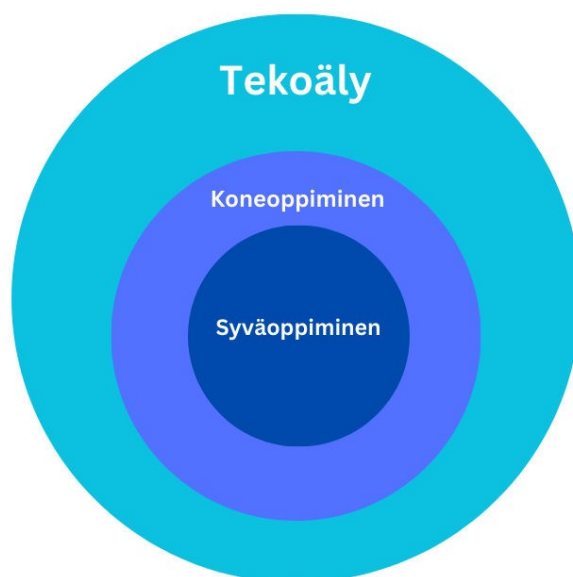
Ohjatun oppimisen algoritmit voidaan jakaa kahteen luokkaan. Ensimmäinen on luokittelu (classification), jossa tietojoukko luokitellaan merkityn datan perusteella (naivi Bayesin luokittelija ja K:n lähimmän naapurin algoritmi). Toinen on regressioanalyysi, joka etsii datasta toistuvia malleja (lineaarinen regressio, ryhmämallinnus ja päätöspuut). (Taulli 2019.)

Ohjaamaton oppiminen (Unsupervised Learning, UL) käsittelee merkitsemätöntä dataa. Ohjaamattomassa oppimisessa käytetään syväoppimisen algoritmeja havaitsemaan datassa toistuvia malleja. Ohjaamaton oppiminen soveltuu datan ryhmittelyyn (clustering), dimensiovähennykseen (dimensionality reduction), eri ominaisuuksien oppimiseen ja assosiaatiotehtäviin. Näistä käytetyin lähestymistapa on ryhmittely, jossa opetukseen käytetään merkitsemätöntä dataa ja hyödynnetään algoritmeja samankaltaisten kohteiden lajitteluun. (Taulli 2019.)

Vahvistusoppiminen (Reinforcement Learning, RL) on oppimismalli, jota voidaan kuvailla tekemällä oppimiseksi kokeilun ja erehdyksen kautta. Vahvistusoppiminen muistuttaa eri koneoppimistekniikoista eniten sitä, miten ihminenkin oppii asioita. Vahvistusoppimisen algoritmi, eli agentti oppii suorittamaan määritellyn tehtävän palautteen avulla, kunnes sen suorituskyyky on toivotulla tasolla. Agentti saa positiivista vahvistusta silloin, kun se suorittaa tehtävän hyvin, ja negatiivista vahvistusta, kun se suorittaa sen huonosti. (What is reinforcement learning 2024.)

2.2 Syväoppiminen ja neuroverkot

Syväoppiminen (Deep Learning, DL) on koneoppimisen metodi, joka perustuu ihmisaivojen toimintaa jäljitteleviin algoritmeihin. Näitä algoritmeja kutsutaan keinotekoisiksi neuroverkoiksi (Artificial Neural Networks, ANN). (Blete & Caelen 2023.) Keinotekoiset neuroverkot käsittelevät valtavia määriä dataa löytääkseen niistä suhteita ja kuvioita, joita ihmiset eivät usein pysty havaitsemaan. Sana ”syvä” viittaa piilotettujen kerrosten määrään neuroverkossa. (Taulli 2019.)



Kuva 1. Tekoäly, koneoppiminen ja syväoppiminen

Vaikka koneoppimisen menetelmiä voidaan käyttää monissa eri ongelmissa, syväoppiminen on tullut hallitsevaksi lähestymistavaksi monimutkaisten tekoälymallien rakentamisessa. Neuroverkot voivat käsitellä suuria datamääriä ja oppia itsenäisesti abstrakteja konsepteja. Esimerkiksi kuvantunnistus, luonnollisen kielen käsittely ja äänentunnistus ovat tekoälyn sovellusalueita, joiden suorituskykyyn syväoppiminen on tuonut merkittävää edistystä. (Blete & Caelen 2023.)

2.2.1 Siirto-oppiminen

Siirto-oppiminen (Transfer Learning) on koneoppimismenetelmä, jossa tiettyyn tehtävään kehitettyä tekoälymallia käytetään lähtökohtana toisen tehtävän mallille. Se on suosittu lähestymistapa syväoppimisessä, koska se säästää aikaa sekä laskentaresursseja ja voi myös parantaa mallin suorituskykyä. (AWS: What is transfer learning.)

Prosessi alkaa usein mallilla, joka on esikoulutettu suurella ja yleisellä data-setillä. Tämä malli on jo oppinut joitakin perusominaisuuksia opetukseen käytystä tietojoukosta. Sen sijaan että koko oppimisprosessi jouduttaisiin aloittamaan alusta, esikoulutettu malli mukautetaan uuteen, mutta samankaltaiseen tehtävään. Tehtävästä riippuen joitakin mallin alkuperäisiä neuroverkkokerroksia, jotka kaappaavat yleisempiä ominaisuuksia pidetään muuttumattomina, ja vain loppukerroksia, jotka kaappaavat tarkempia ominaisuuksia muokataan ja koulutetaan uudelleen. (Transfer learning and fine-tuning.)

Siirto-oppiminen parantaa tekoälymallien suorituskykyä ja tehokkuutta monilla sovellusalueilla, mukaan lukien luonnollisen kielen käsittely (NLP) ja kuvantunnistus.

2.2.2 Takaisinkytketty neuroverkko

Takaisinkytketyillä neuroverkoilla (Recurrent Neural Network, RNN) on ollut iso rooli generatiivisen tekoälyn kehittämisessä, erityisesti sovelluksissa, joissa on kyse jaksottaisen datan käsittelystä (Taulli 2019).

RNN:t on suunniteltu toimimaan perättäisten tietosarjojen, kuten tekstin kanssa. Tämä ominaisuus tekee niistä ihanteellisia generatiivisiin tekoälytehtäviin, joihin kuuluu sellaisen sisällön luominen, jossa järjestyksellä on merkitystä. Esimerkiksi tekstin tuottamisessa jokainen uusi sana riippuu sitä edeltäneiden sanojen kontekstista.

Takaisinkytketyillä neuroverkoilla on eräänlainen muisti. Takaisinkytkeminen tarkoittaa sitä, että ne käsittelevät jokaisen sarjan elementin siten, että ne pystyvät muistamaan tiedot aiemmista syötteistä. (Nabi 2019.)

Vaikka RNN:t olivat avainasemassa varhaisessa generatiivisessa tekoälyssä, niiden toiminnalla on omat rajoituksensa, kuten vaikeus muistaa pitkäaikaisia riippuvuuksia katoavan gradienttiongelman vuoksi. Katoava gradientti tarkoittaa

sitä, että tulosten tarkkuus heikkenee, mitä suuremmaksi neuroverkko kasvaa. Suurten mallien opettaminen voi myös olla työlästä. (Taulli 2019.)

Katoava gradienttiongelma johti kehittyneempien arkkitehtuurien, kuten Long Short-Term Memory (LSTM) ja Gated Recurrent Units (GRU) -arkkitehtuurien kehittämiseen. Ne ovat erikoistuneita neuroverkkoja, jotka vähentävät perinteisten takaisinkytkettyjen neuroverkkojen ongelmia ja toimivat sen vuoksi paremmin generatiivisissa tehtävissä. (Phi 2018.)

2.2.3 Generatiiviset kilpailevat verkostot

Generatiivinen kilpaileva verkosto (Generative adversarial network, GAN) on yksi neuroverkkomalleista, jota käytetään generatiivisen tekoälyn kehittämisessä.

Generatiivinen kilpaileva verkosto koostuu kahdesta erillisestä neuroverkosta: generaattorista ja diskriminaattorista, jotka kilpailevat keskenään. Kilpailevan verkoston tehtävä voi esimerkiksi olla selvittää kuvien aitoutta, jolloin generaattori tuottaa aidolta näyttävän kuvan ja diskriminaattori päättelee, onko kuva aito vai väärennös. (Foster 2023.)

Generaattori pyrkii tuottamaan yhä uskottavampaa dataa, kun taas diskriminaattori pyrkii parantamaan kykyään erottaa aito data keksitystä. Tämä kilpailu johtaa siihen, että generaattori oppii vähitellen tuottamaan yhä parempaa ja aidon näköistä dataa ja diskriminaattori oppii tunnistamaan paremmin väärennöksiä. Kilpailu siis auttaa parantamaan molempien mallien suorituskykyä ajan myötä, mikä mahdollistaa aiempaa uskottavamman ja korkealaatuisemman generoidun datan tuottamisen. (JAMK Syväoppiminen 2024.)

Generaattorin tuottama data voi olla mitä tahansa, kuten kuvia, tekstiä tai musiikkia, riippuen siitä, mitä tekoälymalli on koulutettu generoimaan.

GAN-verkkojen koulutus on haastavaa, sillä generaattorin ja diskriminaattorin on pysyttävä tasapainossa. Jos toinen näistä tulee paljon paremmaksi kuin

toinen, koulutusprosessi ei etene optimaalisesti. Opetuksen aikana molempien mallien suorituskykyä arvioidaan ja niitä säädellään parantamaan tuloksia. GAN-verkkojen kehittäminen ja koulutus vaativat siis suunnittelua, riittävästi laskentatehoa ja syvällistä ymmärrystä koneoppimisen dynamiikasta. (Hui 2018.)

Deepfake-teknologia, jota käytetään elokuvateollisuudessa, mutta myös väärennettyjen kuvien ja videoiden luomisessa, perustuu GAN-verkkoihin. Muita tunnettuja sovelluksia ovat Nvidian kehittämä GauGAN (Alarcon 2019) ja kasvokuvia tuottava StyleGAN. (Aila ym. 2018.)

2.2.4 Variaatioautoenkooderit

Variaatioautoenkooderit (Variational Autoencoders, VAE) ovat syväoppimismalleja, jotka kuuluvat generatiivisiin tekoälymalleihin. VAE-malleja käytetään sovelluksissa eri aloilla, mukaan lukien kuvien generointi ja poikkeavuuksien tunnistaminen. (Foster 2023.)

VAE-mallien käyttökohteita voivat olla esimerkiksi:

- Kuvien generointi: Uusien kuvien luominen, jotka muistuttavat annettua harjoitusdataa.
- Poikkeavuuksien tunnistus: Opettelemalla ensin esittämään normaalia dataa, VAE:t voivat tunnistaa normaalista poikkeavia datapisteitä.
- Kuvien ja äänen kohinanpoisto: Ylimääräisten epäpuhtauksien tai vääristymien tunnistaminen ja poistaminen datasta (Bergman & Stryker 2023).
- Datan injektointi: Tietojoukoista puuttuvien arvojen täydentäminen opettelemalla datan jakautumista.
- Tyylin siirto: Yhden kuvan tyyllillisen ilmeen kopioiminen ja siirtäminen toiseen kuvaan.

Variaatioautoenkooderit oppivat niiden opetukseen käytetyn datan todennäköisyysjakautumina, joita ne pystyvät käyttämään uuden näytedatan tuottamiseen luomalla muunnelmia aiemmin opituista. (Bergman & Stryker 2023.)

Autoenkooderi on neuroverkko, joka koostuu kahdesta osasta: koodaajaverkosta (encoder), joka tiivistää syöttötiedon, kuten kuvan, upotusvektoriin sekä purkajaverkosta (decoder), joka purkaa annetun upotusvektorin takaisin alkuperäiseen muotoon eli takaisin kuvaksi. (Bergman & Stryker 2023.)

VAE erottuu muista autoenkoodereista siinä, että sen käyttämä variaatio-ominaisuus toimii varsinkin tilanneriippuvaisissa graafisissa malleissa (Probabilistic Graphical Model, PGM) ja bayesilaisessa päättelyssä. Se mallintaa latentin tilan käyttäen todennäköisyysjakaumia, tyypillisesti normaalijakaumaa. Tämä mahdollistaa datan generoimisen siten, että siinä voidaan ottaa huomioon epävarmuus ja varianssi, mikä on hyödyllistä erityisesti generatiivisissa sovelluksissa. (Foster 2023.)

Variaatioautoenkoodereita verrataan usein muihin generatiivisiin malleihin, kuten GAN-verkkoihin. Vaikka GAN-verkot tuottavat korkealaatuisia tuloksia, VAE:t ovat yleensä helpompi kouluttaa, ja ne sopivat erityisen hyvin tehtäviin, joissa datan jakautumisen ymmärtäminen on tärkeää.

2.2.5 Transformer-mallit

Transformer-mallit ovat syväoppimisen algoritmeja, jotka ovat nopeuttaneet kehitystä luonnollisen kielen käsittelyssä (NLP) ja muissa tekoälyn sovellusalueissa. Ne julkaistiin ensimmäisen kerran vuonna 2017 Google Brain -tiimin toimesta. (Vaswani ym. 2017.)

Transformer-mallit käyttävät niin kutsuttua itsehuomio mekanismia (self-attention), joka on erityisen hyödyllinen tekstipohjaisen tiedon käsittelyssä, kuten kielen kääntämisessä ja kysymyksiin vastaamisessa, sillä mekanismi auttaa mallia ymmärtämään sanojen välisiä suhteita lauseissa ja teksteissä, riippumatta näiden etäisyydestä toisiinsa. (Blete & Caelen 2023.)

Transformer-arkkitehtuuri on mahdollistanut generatiivisille tekoälymalleille tyypillisen kehittyneen luonnollisen kielen käsittelyn, erityisesti siksi, että ne

ratkaisivat tehokkaasti RNN-verkkojen ongelmat käsitellä pitkiä tekstisekvenssejä. RNN:t tyypillisesti unohtivat kontekstin pidemmissä sekvensseissä, kun taas transformer-malleille tekstin pituus ei tuottanut ongelmia. (Solis 2020.)

Transformer-mallit koostuvat useista peräkkäisistä neuroverkkokerroksista, jotka sisältävät huomioyksiköitä (attention units) sekä muita neuroverkon osia (Vaswani ym. 2017: 2). Tällainen neuroverkkojen arkkitehtuuri mahdollistaa tekoälymalleille monimutkaisten suhteiden ja rakenteiden oppimisen datasta. Koska transformerit eivät käytä rekursiivisia tai konvoluutioelementtejä, ne tarvitsevat mekanismin ymmärtääkseen sanajärjestyksen syötedatassa. Positionaalinen koodaus lisätään syötteeseen kertomaan kullekin osalle sen position lauseessa tai tekstissä. (Vaswani ym. 2017: 6.)

Transformer-mallien tärkeimmät ominaisuudet:

- Itsehuomio (self-attention) eli kyky arvioida kaikkia sekvenssin osia samanaikaisesti, mikä parantaa kontekstuaalista ymmärrystä.
- Tehokas rinnakkaislaskenta, joka mahdollistaa suurten datamäärien käsittelyn, mikä tekee transformereista erittäin skaalautuvia.
- Transformer-mallit ovat joustavia, eli ne soveltuvat monenlaisiin NLP-tehtäviin, kuten kääntämiseen, tekstien ymmärtämiseen ja generointiin sekä myös muihin tehtäviin kuten kuvien ja äänen käsittelyyn.
- Haittapuolena mallien kouluttaminen vaatii paljon laskentatehoa ja koulutusdataa.

2.3 Generatiivisen tekoälyn sovellukset

Generatiivisen tekoälyn käyttömahdollisuudet ovat laajentuneet merkittävästi viime vuosina ja sen sovelluksia hyödynnetään yhä useammilla aloilla, erityisesti tehostamaan usein toistuvia työprosesseja.

Tekstin tuottaminen ja kielten kääntäminen:

- Generatiivista tekoälyä voidaan käyttää kirjoittamaan, referoimaan ja tarkistamaan artikkeleita, raportteja ja luonnoksia.

- Kielten kääntäminen on yksi generatiivisen tekoälyn tunnetuimmista sovelluksista.

Kuvien ja grafiikan generointi:

- Generatiivisia malleja, kuten DALL-E ja Midjourney, voidaan käyttää luomaan kuvia, grafiikkaa ja taideteoksia niille annettujen ohjeiden perusteella.
- Pelien ja virtuaalisten ympäristöjen sisältö: Generatiivista tekoälyä voidaan käyttää luomaan hahmoja, ympäristöjä ja esineitä videopeleihin ja virtuaalitodellisuuteen.

Musiikin ja äänen generointi:

- Musiikin säveltäminen: Tekoälymallit voivat luoda uusia musiikkikapaleita jäljitellen eri genrejä ja tyylejä.
- Puheen generointi: Tekoälyä käytetään luomaan realistista puheääntä tekstistä, mukaan lukien äänikirjat ja virtuaaliavustajat.

Video ja animaatio:

- Videoiden generointi: Vaikka liikkuvan kuvan osalta ollaan vielä kehityksellisesti jäljessä muita generatiivisia sovelluksia, on jo olemassa järjestelmiä, jotka kykenevät luomaan videoita tai animaatioita annetuista käsikirjoituksista tai kuvauksista.
- Elokuvien ja videoiden jälkituotanto: Tekoäly voi jo nyt auttaa luomaan realistisia erikoistehosteita tai muuttamaan videokuvaa.
- Animoitujen hahmojen generointi: Tekoälyllä voidaan luoda animoituja hahmoja ja antaa niille luonnollisia liikkeitä ja ilmeitä.

Data-analyysi ja visualisointi:

- Data-analyysin ennustemallit: Generatiivista tekoälyä käytetään ennustamaan markkinatrendejä, sääilmiöitä ja muita datan avulla ennustettavia ilmiöitä.
- Visualisointi: Tekoäly pystyy visualisoimaan suuria datamääriä interaktiivisesti ja ymmärrettävästi.

Ohjelmistotuotanto:

- Tekoäly voi auttaa koodaamaan, kommentoimaan ja tarkistamaan valmista koodia annettujen ohjeiden perusteella, mikä nopeuttaa kehitysprosesseja.

Henkilökohtaiset avustajat ja chatbotit:

- Virtuaaliavustajat: Generatiivista tekoälyä hyödynnetään virtuaaliavustajissa, kuten Amazonin Alexa ja Applen Siri, jotka ymmärtävät ja tuottavat luonnollista kieltä ja pystyvät auttamaan käyttäjiä monenlaisissa tehtävissä.

Generatiivisen tekoälyn käyttö opetuksessa:

- Oppimateriaalin tuottaminen: Generatiivinen tekoäly soveltuu hyvin eri tehtävätyyppien luomiseen sekä digitaalisten oppimisalustojen kehittämiseen.
- Tehtävien tarkastaminen: Tekoälyn hyödyntäminen tehtävien tarkastamisessa säästää opetushenkilökunnan aikaa. Se mahdollistaa myös automaattisen palautteenannon, esimerkiksi kertomalla opiskelijalle minkä tyyppiset virheet ovat toistuvia.
- Simulaatiot ja koulutus: Generatiivista tekoälyä voidaan käyttää luomaan realistisia simulaatioita ja koulutusmateriaaleja opiskelijoille ja ammattilaisille.

Generatiivinen tekoäly terveydenhuollossa:

- Lääketieteellisten kuvien analysointi: Generatiivinen tekoäly voi auttaa luomaan tarkempia lääketieteellisiä kuvia, kuten MRI- tai CT-kuvia, parantaen diagnoosien tarkkuutta. Lisäksi se voi auttaa tunnistamaan sairauksia kuvista, joita ihmissilmä ei ehkä havaitse.
- Ennakoiva analytiikka terveydenhuollossa: Generatiivinen tekoäly voi ennustaa epidemioita, sairaaloiden potilasmääriä ja potilaiden terveysriskejä, mahdollistaen resurssien paremman kohdentamisen ja ennaltaehkäisevien toimenpiteiden suunnittelun.
- Automaattinen raportointi ja dokumentointi: Tekoäly voi auttaa automatisoimaan lääketieteellisen raportoinnin ja potilasdokumentaation, vähentäen terveydenhuollon ammattilaisten hallinnollista taakkaa ja mahdollistaen heidän keskittymisen potilaiden hoitoon.

2.4 Generatiivisen tekoälyn haasteet ja tulevaisuus

Generatiivisen tekoälyn haasteet ja tulevaisuus kattavat valtavan määrän kysymyksiä teknisistä ja eettisistä kysymyksistä säädöksellisiin ja yhteiskunnallisiin ongelmiin.

Yksi suurimmista haasteista on tekoälyn luomien teosten eettisyys ja tekijänoikeudet, jotka herättävät keskustelua siitä, kuka omistaa tekoälyn luomat teokset ja kuinka näitä teoksia tulisi säädellä. Lisäksi tekoälyn kouluttaminen vaatii valtavia datamääriä, mikä herättää huolta yksityisyydensuojasta ja tietoturvasta.

Toinen keskeinen haaste on tekoälyn tuottamien tulosten puolueellisuus, joka voi syntyä koulutusaineiston vinoumista. Tämä voi johtaa syrjintään ja vääristymiin, jotka vahvistavat olemassa olevia ennakkoluuloja yhteiskunnassa. Ratkaisut näihin ongelmiin vaativat monitahoisia lähestymistapoja, kuten parempaa datan seulomista ja uusien, eettisten ohjeistojen kehittämistä.

Tulevaisuudessa generatiivinen tekoäly tulee suurella todennäköisyydellä muuttamaan monia aloja, kuten ohjelmistoalan ja sisällöntuotannon, taiteen, viihteen ja koulutuksen. Kehityksen myötä tekoälystä tulee entistä luovempaa ja itsenäisempää, mutta samalla on tärkeää korostaa ihmisen roolia sen ohjaajana ja valvojana.

3 Laajat kielimallit

Laajat kielimallit (Large Language Models, LLM), kuten OpenAI:n GPT-mallit, Metan Llama-mallit ja Googlen LaMDA ovat keskeinen osa generatiivisen tekoälyn kehitystä, varsinkin kun puhutaan tekstipohjaisen sisällön tuottamisesta. Nämä mallit perustuvat Googlen kehittämään transformer-arkkitehtuuriin, joka on mahdollistanut tekoälyn opettamisen suurilla datamäärillä ja kyvyn tuottaa monipuolista ja yhtenäistä tekstiä. (Foster 2023.) Vaikka laajojen kielimallien opettamisprosessi on suhteellisen yksinkertainen, koulutukseen vaadittavat suuret taloudelliset ja laskennalliset resurssit ovat rajanneet laajojen kielimallien kehityksen vain muutaman suuren teknologiayrityksen käsiin. (Touvron ym. 2023: 3.)

3.1 Luonnollisen kielen käsittely

Luonnollisen kielen käsittely (Natural Language Processing, NLP), on tekoälyn ja kielitieteen ala-alue. NLP hyödyntää koneoppimisen menetelmiä ymmärtääkseen, tulkitakseen ja tuottaakseen luonnollista kieltä, mikä tekee siitä erityisen sovellusalueen koneoppimisen sisällä.

Luonnollisella kielellä tarkoitetaan ihmisten käyttämiä kieliä päivittäisessä kommunikaatiossa. Ne ovat kieliä, jotka ovat kehittyneet luonnollisesti kulttuuristen ja historiallisten prosessien kautta (kuten suomi tai englanti), toisin kuin keinotekoisesti luodut kielet, kuten ohjelmointikielet tai esperanto. Luonnolliset kielet sisältävät monimutkaisia kieliopillisia ja semanttisia sääntöjä, ja niitä käytetään ilmaisemaan ajatuksia, tunteita ja tietoa. (Ojutkangas ym. 2013: 192.)

Koska laajat kielimallit on suunniteltu ymmärtämään ja tuottamaan luonnollista kieltä, ne voivat generoida uskottavaa tekstiä, vastata kysymyksiin, kirjoittaa artikkeleita, ylläpitää keskustelua, kääntää eri kieliä ja kirjoittaa koodia. Niiden kyky ymmärtää kontekstia ja säilyttää yhtenäisyys tuotetussa tekstissä tekee niistä erittäin tehokkaita generatiivisen tekoälyn sovelluksissa.

Koneoppiminen on mahdollistanut sellaisten tekoälymallien kehittämisen, jotka voivat oppia kielen rakenteita, sääntöjä ja merkityksiä valtavista määristä tekstidataa. Oppiminen voi tapahtua ohjatusti, ohjaamattomasti tai vahvistusoppimisen kautta riippuen tehtävästä ja käytettävissä olevasta datasta.

Vaikka koneoppiminen kattaa laajan joukon menetelmiä myös tekstinkäsittelyyn, syväoppimisella on erityisen tärkeä rooli nykyaikaisessa NLP:ssä (Russell 2021: 932). Syväoppimisen mallit, erityisesti transformer-mallit, ovat osoittautuneet erittäin tehokkaiksi monimutkaisten kielellisten rakenteiden ja merkitysten oppimisessa (Russell 2021: 944). Esimerkkejä näistä ovat chatbotit, ääniavustajat ja automaattiset kääntäjät.

3.2 Keskusteleva tekoäly

Keskusteleva tekoäly (usein myös chatbot) on tekoälyn sovellus, joka on suunniteltu simuloimaan ihmisten välistä keskustelua. Tällaiset järjestelmät perustuvat usein luonnollisen kielen käsittelyn tekniikoihin, joiden avulla järjestelmä voi ymmärtää, prosessoida ja tuottaa luonnollista kieltä.

Keskustelevien tekoälysovellusten kehitys alkoi 1960-luvulla, kun tietotekniikka ja tekoälytutkimus olivat vielä varhaisessa vaiheessa. Yksi ensimmäisistä merkittävistä esimerkeistä on Joseph Weizenbaumin luoma ELIZA, joka kehitettiin 1966. ELIZA oli ohjelma, joka simuloi keskustelua psykoterapeutin ja potilaan välillä, käyttäen melko yksinkertaisia sääntöihin perustuvia menetelmiä tekstin syötön tunnistamiseen ja vastausten tuottamiseen. (Weizenbaum 1966: 36.)

1970-luvulla psykiatri Kenneth Colby kehitti PARRY-nimisen chatbotin, joka oli ELIZA:a parempi mallintamaan keskustelua (Saygin ym. 2000: 500). 1980- ja 1990-luvuilla tekoälyn kehitys jatkui, ja tietokoneiden teho sekä algoritmien kehittyminen mahdollistivat entistä monimutkaisempien keskustelevien järjestelmien rakentamisen.

2000-luvulle tultaessa koneoppiminen ja erityisesti syväoppiminen vauhdittivat keskustelevien tekoälyjen kehitystä. Modernit chatbotit, kuten OpenAI:n ChatGPT, ovat kehittyneet käyttämään valtavia datamääriä ja monimutkaisia neuroverkkoja, jotka voivat tuottaa koko ajan inhimillisempiä ja sisällöllisesti relevantteja keskusteluja.

Keskustelevia tekoälyjä käytetään monilla eri aloilla, kuten asiakaspalvelussa, terveydenhuollossa, koulutuksessa ja viihteessä. Ne tarjoavat yrityksille mahdollisuuden parantaa asiakaskokemusta automatisoimalla vastauksia usein kysytyihin kysymyksiin, tarjoamalla henkilökohtaista apua tai jopa suorittamalla monimutkaisempia tehtäviä, kuten varauksia tai ostoprosesseja.

Keskustelevien tekoälysovellusten kehitys- ja julkaisupaineet ovat kuitenkin johdaneet siihen, että teknologiayritykset ovat julkaisseet keskeneräisiä sovelluksia,

joissa on esiintynyt monia ongelmia, kuten väärää tai puolueellista tietoa tai jopa suoranaista vihapuhetta (Hsiao & Manyika 2023).

3.2.1 OpenAI:n ChatGPT

Marraskuussa 2022 yhdysvaltalainen teknologiayritys OpenAI esitteli Chat Generative Pre-trained Transformerin, joka tunnetaan paremmin nimellä ChatGPT. ChatGPT koulutettiin 570 gigatavun tekstidatalla, eli 100 kertaa suuremmalla datamäärällä kuin sitä edeltävä GPT-2 malli. (Introducing ChatGPT 2022.)

ChatGPT toimii parhaiten keskustelukonteksteissa, ja se osaa tuottaa vastauksia, jotka ovat asiayhteyteen sopivia ja luonnollisia. Se pystyy myös oppimaan käyttäjän edellisten kysymysten ja vastausten perusteella, mikä tekee siitä kykenevän ylläpitämään keskustelua ja reagoimaan monimutkaisiinkin aiheisiin.

OpenAI myönsi, että malli julkaistiin keskeneräisenä. ChatGPT:n puutteisiin kuului muun muassa rajattu tietämys ajankohtaisista asioista (sen koulutusdata ulottui vuoden 2022 alkuun saakka), uskottavien mutta virheellisten vastausten tuottaminen sekä haitallisen tai puolueellisen tiedon antaminen. ChatGPT saavutti miljoona käyttäjää vain viidessä päivässä julkaisun jälkeen. (Introducing ChatGPT 2022.)

OpenAI:n päätös julkaista ChatGPT on saanut kritiikkiä useilta tahoilta, joiden mielestä oli vastuutonta julkaista järjestelmä, joka ei ainoastaan saata aiheuttaa merkittäviä riskejä yhteiskunnalle ja ihmisille, vaan myös käynnistää tekoälykilvan, jossa yritykset valitsevat nopeuden varovaisuuden sijaan. OpenAI:n perustajajäsen Sam Altman on todennut, että uuden teknologian asteittainen julkaiseminen maailmalle on kuitenkin turvallisempaa, jotta kaikki voivat paremmin ymmärtää tekoälyyn liittyvät riskit ja kuinka hallita niitä, jos kehitys tapahtuisi täysin suljettujen ovien takana. OpenAI myös totesi, että kielimallien hienosäätäminen ihmisten avulla voi olla tehokas työkalu mallien turvallisuuden ja luotettavuuden parantamiseksi. (Dhamani & Engler 2024.)

Maaliskuussa 2023 OpenAI julkaisi GPT-4:n, suuren multimodaalisen mallin, joka pystyy vastaanottamaan ja tuottamaan teksti- ja kuvasyötteitä (GPT-4 Technical Report 2023).

3.2.2 Metan Llama-mallit

Meta julkisti tekoälyassistentti Meta AI:n helmikuussa 2023. Meta AI pohjautuu avoimen lähdekoodin Llama-kielimalleihin, jotka julkaistiin 7, 13, 33 ja 65 miljardin parametrin kokoisina. Yksityiskohtaisessa tutkimusraportissa kerrottiin, miten mallit oli rakennettu. Raportissaan Meta väitti, että 13 miljardin parametrin malli, toiseksi pienin, suoriutuu useimmista vertailukohteista paremmin kuin GPT-3, kun taas suurin 65 miljardin parametrin malli on kilpailukykyinen julkaisuaikansa parhaiden LLM:ien, kuten Googlen PaLM:n kanssa. (Touvron ym. 2023: 6.)

Llaman julkaisun tarkoitus oli auttaa demokratisoimaan laajojen kielimallien käyttöä julkaisemalla pienempiä, tehokkaita malleja, jotta tutkijat voisivat löytää uusia lähestymistapoja tekoälyn hyödyntämiseen ja sen käyttöön liittyvien riskien havaitsemiseen. Llama julkaistiin tutkimuskäyttöön tarkoitetulla ei-kaupallisella lisenssillä. (Dhamani & Engler 2024.)

Heinäkuussa 2023 Meta julkaisi Llama 2:n, seuraavan sukupolven avoimen lähdekoodin mallin ilmaiseksi tutkimus- ja kaupalliseen käyttöön. Llama 2 on esikoulutettu julkisesti saatavilla olevilla verkkoaineistoilla. Hienosäädetty malli, Llama Chat, hyödyntää julkisesti saatavilla olevia ohjeistusaineistoja ja yli miljoonaa ihmisen tekemää merkintää. (Llama 2. 2023.) Kielimalli Llama 3 julkaistiin huhtikuussa 2024 (Introducing Meta Llama 3 2024).

3.2.3 Googlen LaMDA ja PaLM

Tammikuussa 2020 Google julkisti Meena-nimisen 2,6 miljardin parametrin keskusteleavan tekoälyjärjestelmän, joka perustuu transformer-arkkitehtuuriin. Googlen tekoälytutkijat selvittivät julkaisemassaan tutkimuksessa, että

transformer-pohjaiset mallit, jotka on koulutettu dialogiin, pystyvät keskustelemaan käyttäjän kanssa lähes mistä tahansa. (Adiwardana ym. 2020.) Meenaa ei koskaan avattu julkiseen käyttöön turvallisuusperiaatteiden rikkomisen vuoksi.

Google LaMDA (Language Model for Dialogue Applications) julkaistiin Googlen I/O-kehittäjäkonferenssissa toukokuussa 2021. LaMDA oli suunniteltu osallistumaan vapaamuotoiseen ja luonnolliseen keskusteluun käyttäjien kanssa. Samalla tuotettiin relevantteja vastauksia meneillään olevaan keskusteluun. Meenan pohjalta rakennettu LaMDA koostui 137 miljardista malliparametrusta ja siinä oli uudelleen suunniteltuja mittareita laadun, turvallisuuden ja mallin suorituskyvyn mittaamiseksi. Seuraavana vuonna Google ilmoitti LaMDA:n toisesta julkaisusta. (Collins & Ghahramani 2021.)

Google kiirehti tuomaan markkinoille oman keskustelubottinsa nähtyään eri kilpailijoiden kehittävän chatbotteja transformer-pohjaisilla malleilla, arkkitehtuurilla, joka alun perin kehitettiin Googlessa. Se julkaisi Bardin maaliskuussa 2023 testikäyttöön. (Hsiao & Manyika 2023.) Bard toimi itsenäisellä verkkosivulla sen sijaan, että se olisi yhdistetty suoraan Googlen hakukoneeseen.

Kuten OpenAI aiemmin niin myös Google totesi, että keskusteleva tekoäly tuottaa ajoittain myös väärää tai loukkaavaa tietoa (Hsiao & Manyika 2023). Bard sai paljon kritiikkiä eikä onnistunut päihittämään ChatGPT:n saamaa huomiota.

Googlen Bardin alkuperäinen versio oli kevyempi LaMDA-malli, jota parannettiin pian Pathways Language Model (PaLM) -mallilla. Joulukuussa 2023 Google Bard korvattiin Geminillä, joka on 540 miljardin parametrin transformer-pohjainen, multimodaalinen malli. (Introducing Gemini 2023.)

Google PaLM (Pathways Language Model)

PaLM on rakennettu Pathways-järjestelmän pohjalta, joka tukee isojen tekoälymallien skaalautuvaa ja tehokasta kouluttamista. Tämän ansiosta PaLM pystyy käsittelemään ja oppimaan suuria määriä tietoa. Googlen tutkijatiimi korostaa,

että PaLM suoriutui erinomaisesti monissa vertailutesteissä, mikä osoittaa selvää edistystä aiempiin malleihin verrattuna niin kielten ymmärtämisessä kuin ongelmanratkaisutehtävissäkin. (Chowdhery & Narang 2022.)

Google PaLM nähdään osana tekoälyn kehityksessä tapahtuvaa laajempaa suuntausta, jossa keskitytään tehokkaampien ja paremmin yleiseen käyttöön sopivien mallien rakentamiseen. PaLM:in kaltaiset mallit kykenevät sopeutumaan erilaisiin työtehtäviin ilman laajamittaista uudelleenkoulutusta. Tehtävien moniajokyky on yksi merkittävä askel kohti yleistyneempiä tekoälyjärjestelmiä. (Chowdhery & Narang 2022.)

3.3 Multimodaaliset mallit

Generatiivisen tekoälyn laajat kielimallit, kuten vanhemmat GPT-versiot, keskittyivät pääasiassa tekstin käsittelyyn ja tuottamiseen, mutta uudet mallit on suunniteltu monimuotoisiksi eli multimodaalisiksi. Nämä mallit pystyvät ymmärtämään ja luomaan uutta dataa tekstin lisäksi kuvista, äänestä ja videoista. (Foster 2023.) Tätä edistysaskelta pidetään ratkaisevana älykkäämmille tekoälyjärjestelmille, jotka tarvitsevat toimiakseen kattavampaa ymmärrystä maailmasta. Se puolestaan on saavutettavissa vain analysoimalla monenlaisia tietotyyppisiä samanaikaisesti kuten ihminenkin tekee näön, kuulon ja puheen avulla.

Esimerkkejä multimodaliteetista ovat tekoälyjärjestelmät, jotka voivat katsoa videota ja kuvailla, mitä siinä tapahtuu, chatbotit, jotka ymmärtävät käyttäjien lähettämiä kuvia ja vastaavat niihin sopivasti, tai sovellus, joka voi luoda tarkkoja kuvatekstejä valokuville.

Googlen robotiikkaa ja keskustelevaa tekoälyä yhdistävä malli PaLM-E (Embodied Multimodal Language Model) hyödyntää Googlen kehittämää Vision Transformeria. Se muuntaa visuaaliset ja sensoriset tiedot tokeneiksi, jotka voidaan lomittaa robotille annettavien tekstiohjeiden kanssa. Tämä mahdollistaa tekoälyroboteille yhä monimutkaisempien tehtävien suorittamisen tekstikehotteiden

ja aistimodaliteettien jatkuvan palautteen perusteella. (Foster 2023: luku 14, Driess ym. 2023.)

Multimodaalisten mallien kehittämisellä tulee olemaan merkittäviä vaikutuksia siihen, miten tekoälyä voidaan soveltaa eri sektoreilla terveydenhuollosta ja koulutuksesta viihteeseen ja asiakaspalveluun.

3.4 Kehotesuunnittelu

Kehotesuunnittelu (prompt engineering) on prosessi, jossa luodaan tai muokataan generatiiviselle tekoälylle annettavia syötteitä eli kehoitteita (prompteja). Käyttäjän antamilla kehoitteilla ohjataan tekoälyn toimintaa, jotta sen antamat vastaukset vastaisivat mahdollisimman tarkasti ja tehokkaasti haluttua lopputulosta (Ojanperä 2023: 41). Kehotesuunnittelun avulla käyttäjä voi ohjata generatiivista tekoälyä tuottamaan tietyn tyyppistä sisältöä, kuten kirjoittamaan tietyn tyylistä tekstiä, generoimaan erilaisia ideoita tai luomaan tietyn tyylistä taidetta. Multimodaalisten mallien kehittymisen myötä kehoitteet voivat sisältää myös kuvia tai ääntä, jolloin käyttäjä voi pyytää tekoälyä luomaan näitä muistuttavan tuotoksen tai käyttämään jotain kehoitteen osaa uuden pohjana.

Kehotesuunnittelu on erityisen tärkeää, kun käytetään laajoja kielimalleja, kuten GPT-malleja, jotka voivat tuottaa monenlaisia vastauksia riippuen siitä, miten kysymys tai kehoitus on sille muotoiltu. Hyvin muotoiltu kehoite auttaa tekoälyä ymmärtämään, mitä siltä pyydetään, mikä puolestaan johtaa tarkempiin ja sisällöllisesti relevantteihin vastauksiin. (Ye ym. 2023.)

Tarkasti muotoillut kehoitteet helpottavat tekoälyä ymmärtämään ja suorittamaan myös monimutkaisempia tehtäviä, kuten moniosaisia matemaattisia laskutoimituksia tai tuottamaan koodia (Prompt Engineering 2024).

Kehotesuunnittelun päävaiheet voidaan jakaa viiteen osa-alueeseen: tavoitteen määrittäminen, kehoitteen luominen, kehoitteen testaaminen, säätäminen ja toisto (Ojanperä 2023: 43).

4 GPT:n kustomointi

Tämän opinnäytetyöprojektin yhtenä tavoitteena oli luoda kustomoitu versio ChatGPT-mallista käyttäen OpenAI:n GPT Builder -työkalua.

GPT Builder on web-sovellus, jonka avulla käytännössä kuka tahansa voi kustomoida ChatGPT:stä mallin, joka vastaa omiin tai yrityksen tarpeisiin ilman suuria kustannuksia, omia teknisiä resursseja tai koneoppimiseen ja tekoälymallien kouluttamiseen vaadittavaa tuntemusta.

Räätälöidyt GPT-mallit vastaavat geneeristä ChatGPT:tä paremmin käyttäjien tarpeisiin esimerkiksi toimimalla asiakastukena, nopeuttamalla verkkosivustojen ja sosiaalisen median sisällöntuotantoa tai tehostavat oppimista toimimalla tutorina. Ne on myös mahdollista yhdistää ulkopuoliseen verkkopalveluun tai tietokantaan API-rajapintaa käyttämällä.

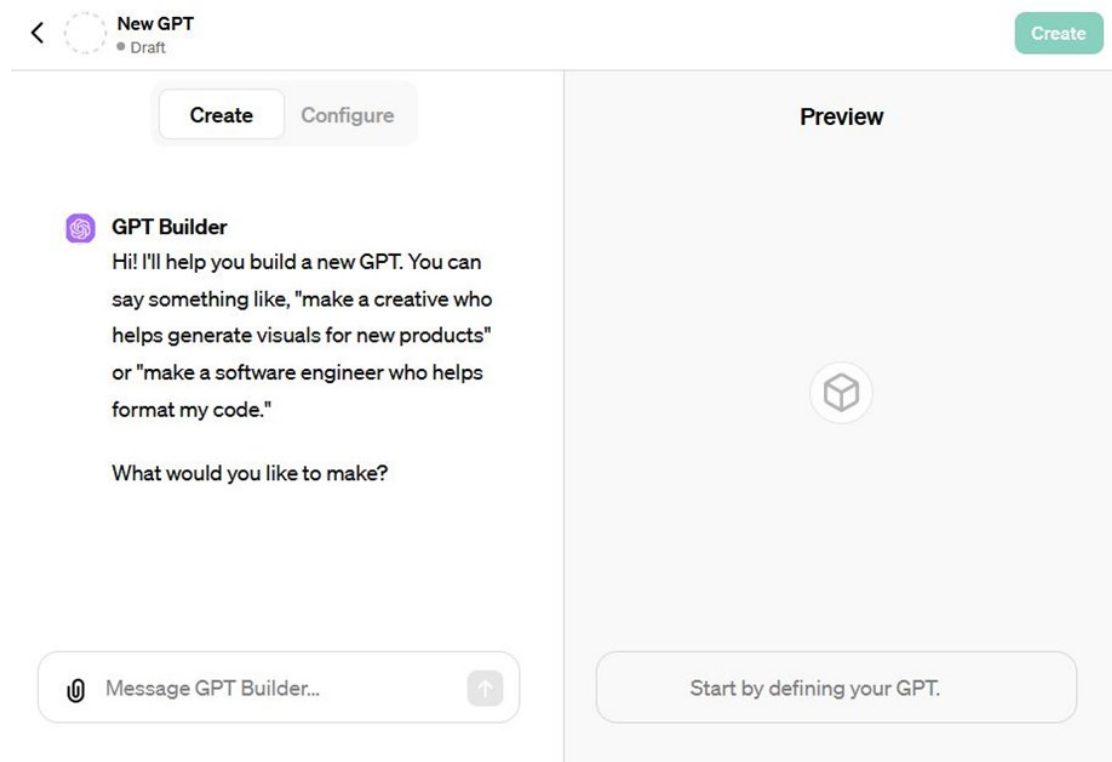
Projektin tavoitteena oli kehittää suomenkielinen, kustomoitu versio GPT-mallista, joka on erityisesti suunniteltu toimimaan käyttäjän apukokkina. Pää tavoitteena oli, että chatbot ehdottaa käyttäjille terveellisiä kotiruokareseptejä, tarjoaa ostoslistan sekä yksityiskohtaista ravitsemustietoa kustakin reseptistä. Ravitsemustiedot se hakee API-rajapinnan kautta Terveystietokeskuksen ja hyvinvoinninlaitoksen ylläpitämästä avoimesta Fineli-tietokannasta.

4.1 GPT-Builder-työkalu ja toiminnallisuudet

GPT Builderin käyttäminen edellyttää rekisteröitymisen chat.openai.com-sivustolle sekä kuukausimaksullisen käyttäjälisenssin, jonka hinta huhtikuussa 2024 oli 20 dollaria (ChatGPT Pricing 2024).

Oman GPT:n luominen onnistuu GPT Builderissa kahdella eri tavalla. GPT Builder on rakennettu ChatGPT:n ominaisuuksilla, joten yksinkertaisimmillaan uuden GPT:n luominen onnistuu kertomalla GPT Builderille, mitä haluaa oman mallinsa tekevän. Mitä tarkemmin Builderissa kuvailee GPT:n

käyttötarkoituksen ja miten haluaa sen toimivan, sen parempaa jälkeä GPT Builder tuottaa (kuva 2).



Kuva 2. Uuden GPT:n luominen GPT Builder -työkalulla.

Toinen vaihtoehto on konfiguroida GPT itse. Se tapahtuu GPT Builderin configure-välilehdellä (kuva 3).

< New GPT
• Draft

Create Configure

+

Name
Name your GPT

Description
Add a short description about what this GPT does

Instructions
What does this GPT do? How does it behave? What should it avoid doing?

Preview

Message GPT...

Kuva 3. GPT:n konfigurointi: nimeäminen, kuvaus ja ohjeet.

GPT:lle voi antaa nimen (name) ja lyhyen kuvauksen (description) sekä lisätä kuvan tai vaihtoehtoisesti antaa kuvageneraattori DALL-E:n luoda sen. Varsinaiset ohjeet mallin toiminnasta annetaan sille instructions-tekstikentässä (kuva 4).

**Name**

Hyvän olon kotiruokabotti

Description

Tarjoaa terveellisiä reseptejä ja ravitsemustietoja.

Instructions

Hyvän olon kotiruokabotti on suunniteltu auttamaan käyttäjiä luomaan ravitsevia ateriasuunnitelmia suomeksi. Se ehdottaa reseptejä ottaen huomioon ruokavaliot ja mieltymykset sekä tarjoaa yksityiskohtaiset ravintoainetiedot kullekin reseptille. Lisäksi Hyvän olon kotiruokabotti voi luoda ostoslistoja, joiden avulla käyttäjät voivat helposti hankkia tarvittavat ainesosat aterioihinsa. Tämä GPT yhdistää Finelin API:n hakeakseen tarkkoja ravitsemustietoja, varmistaen luotettavan ja käyttökelpoisen ruokatiedon terveellisen ruokavalion ylläpitämiseksi. Hyvän olon kotiruokabotti on ystävällinen ja kannustava.

Conversation starters

Miten voin lisätä proteiinia aterioihini?

✕

Mitä aineksia tarvitsen terveelliseen smoothieen?

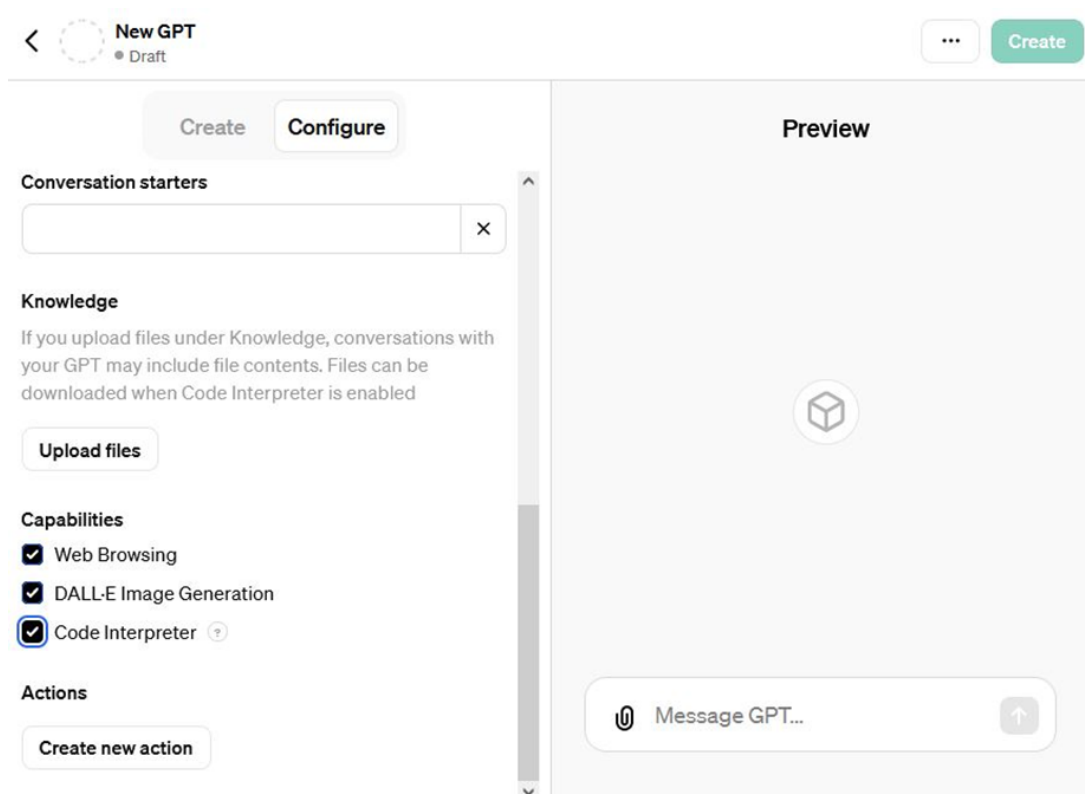
✕

Voisitko suositella kasvisruokia illalliseksi?

✕

Kuva 4. Valmiin chatbotin kuvaus ja sille annettu ohjeistus

Keskustelun avaukset (conversation starters) ovat kehittäjän etukäteen määrittämiä lauseita, joilla käyttäjä voi helposti aloittaa keskustelun chatbotin kanssa. configure-välilehdeltä löytyvät myös Knowledge- ja Actions-toiminnot (kuva 5).



Kuva 5. GPT:n konfigurointi: keskustelun avaukset, Knowledge, lisävalinnat ja Actions.

4.1.1 Knowledge-toiminto

GPT:n Knowledge-toiminto on GPT Builderin sisäinen tiedonhallintajärjestelmä. Sen avulla kustomoituun GPT:hen voi liittää jopa 20 tiedostoa. Yksittäisen tiedoston koko voi olla enintään 512 MB. Tiedostot voivat sisältää myös kuvia, mutta tällä hetkellä GPT pystyi hakemaan niistä vain tekstiä. Tiedoston lataamisen yhteydessä GPT jakaa tekstin osiin, luo niistä sisäisiä esityksiä (embeddings) ja tallentaa ne myöhempää käyttöä varten. Knowledge-toiminnon käyttö edellyttää, että GPT:lle on konfiguroinnin yhteydessä sallittu kooditulkin (code interpreter) käyttö. (Knowledge in GPT's 2024.)

Kun käyttäjä keskustele chatbotin kanssa, GPT pääsee käsiksi ladattuihin tiedostoihin hakeakseen lisätietoa, josta voi olla apua täydentämään käyttäjän kyselyä. Menetelmät, joita GPT käyttää tiedonhakuun, ovat semanttinen haku sekä asiakirjan noutaminen osittain tai kokonaan. Kehittäjä voi GPT Builderin

instructions-osiossa lisätä GPT:lle ohjeistuksen siitä, että sen tulisi hakea vastauksia käyttäjän kyselyyn ensisijaisesti ladatuista tiedostoista sen sijaan, että se hakisi niitä internetistä.

4.1.2 Actions-toiminto ja API-rajapinnat

GPT Actions -toiminto mahdollistaa kustomoidun GPT:n yhdistämisen ulkopuolisen verkkopalvelun tai sovelluksen ohjelmointirajapintaan. Toiminnot määritellään käyttäen OpenAPI-spesifikaatiota, joka on standardi API:en kuvaamiseen.

GPT Actions lisää kustomoidun GPT:n toimintoja ja hyödyntämismahdollisuuksia käytännön sovelluksissa ja työtehtävissä. Kun GPT:llä on mahdollisuus API-rajapintoja hyödyntämällä vuorovaikutukseen ulkoisten palveluiden kanssa. Kehittäjillä on mahdollisuus luoda monipuolisempia sovelluksia, jotka pystyvät suorittamaan erilaisia tehtäviä, joihin geneerinen ChatGPT ei pysty, kuten hakemaan vastauksia kyselyihin ajantasaisilla tiedoilla tai vaikka vastaamaan sähköposteihin ja ohjaamaan älylaitteita.

Actions-toiminnon osat ovat autentikointi (authentication), Open API skeeman (schema) määrittäminen ja tietosuojalausekkeen lisääminen (privacy policy) (kuva 6).

<

Edit actions

🗑️

Let your GPT retrieve information or take actions outside of ChatGPT.
[Learn more.](#)

Authentication

None ⚙️

Schema Import from URL Examples ▾

```

{
  "openapi": "3.0.0",
  "info": {
    "title": "Fineli",
    "description": "Fineli koostumustietokannan avoin data",
    "version": "1.0",
    "termsOfService": "https://fineli.fi/fineli/fi/avoain-data",
    "license": {
      "name": "Creative Commons 4.0 CC-BY"
    }
  },
  "servers": [
    {
      "url": "https://fineli.fi/fineli"
    }
  ],
  "tags": [
    {
      "name": "component-controller",
      "description": "Component Controller"
    },
    {
      "name": "food-controller",
      "description": "Food Controller"
    }
  ]
}

```

Format

Available actions

Name	Method	Path	
listComponentsUsingGET	GET	/api/v1/components	Test

Kuva 6 GPT:n konfigurointi: Actions-toiminto API-rajapintojen hyödyntämiseen.

OpenAI ei itsenäisesti tarkista API-tarjoajan yksityisyys- ja turvallisuuskäytäntöjä, ja se kehottaakin käyttämään vain luotettuja palveluja.

Ulkopuolisen API-rajapinnan käyttäminen GPT Builderissa edellyttää lisäämään linkin käytettävän palvelun tietosuojalausekkeeseen (privacy policy), jotta kustomoidun GPT:n voi julkaista.

Kustomoidun GPT:n yhdistäminen ulkopuoliseen tietokantaan

API (Application Programming Interface) eli ohjelmointirajapinta on joukko määrittelyksiä, joiden avulla eri ohjelmistot voivat kommunikoida keskenään. API mahdollistaa ohjelmistojen tai niiden osien välisten rajapintojen hallinnan, mikä

tarkoittaa sitä, että kehittäjät voivat rakentaa sovelluksia, jotka voivat hyödyntää toisten ohjelmistojen toimintoja ja dataa. Esimerkiksi verkkosivusto voi käyttää sääpalvelun API:a hakeakseen reaaliaikaiset säätiedot.

API-rajapinnan integrointi oli yksi tämän projektin keskeinen osa. API-yhteys mahdollistaa sen, että kustomoitu chatbot pystyy hakemaan THL:n ylläpitämästä Fineli-ravintotietokannasta reaaliaikaista, tarkkaa ravintotietoa jokaisesta ehdotetuissa resepteissä käytetystä ainesosasta. Fineli-ravintotietokanta kattaa laajan valikoiman elintarvikkeita, mikä vaikutti hyödylliseltä lisältä sovelluksen toiminnalle ja antoi samalla mahdollisuuden testata, miten GPT yhdistetään ulkoiseen palveluun.

Integrointiprosessi sisälsi Open API -skeeman määrittelyn mukautetun GPT-mallin ja Fineli API:n välille. Tämä rajapinta käsittelee API-pyyntöjä ja -vastauksia varmistaen, että malli pystyy kysymään Fineli API:lta ravintotietoja reseptien ainesosien perusteella ja sisällyttämään nämä tiedot vastauksiinsa käyttäjille. Finelin API:lle ei ollut olemassa ajantasaista Open API -skeemaa, joten se piti muokata Finelin Swagger 2.0 API -dokumentaatiosta uudempaan Open API 3.0 -muotoon.

API-skeema on dokumentaatio, joka määrittelee, miten ohjelmointirajapinta on rakennettu ja miten sitä käytetään. Se kuvaa API:n tarjoamat resurssit, päätepisteet (eli ne osoitteet, joihin API-kutsut lähetetään), tuetut operaatiot (kuten GET, POST, DELETE) ja datan esitysmuodot. Skeema voi sisältää tietoja parametreista, vastausmuodoista, mahdollisista virheilmoituksista ja muista turvallisuuden tai autentikointiin liittyvistä vaatimuksista. (Bilal 2022.)

Open API Specification (OAS) määrittelee standardin eli kielestä riippumattoman rajapinnan HTTP API:lle. Kun se on määritelty asianmukaisesti, käyttäjä voi olla vuorovaikutuksessa ulkopuolisen sovelluksen tai tietokannan ominaisuuksiin ilman pääsyä lähdekoodiin, dokumentaatioon tai verkkoliikenteen tarkasteluun. (OpenAPI Specification 2021.)

Autentikointi

GPT-Builderin API -toiminnoissa on käyttäjien tunnistamiseen kolme eri vaihtoehtoa: "None" (ei mitään), "API-key" (Api-avain) ja "OAuth". Jos OAuth tunnistautuminen vaaditaan, chatbotin käyttäjää pyydetään kirjautumaan sisään istunnon aikana, mikäli tietoja halutaan hakea ulkopuolisesta palvelusta.

Projektissa hyödynnettyä Finelin tietokantaa voi käyttää Creative Commons 4.0 -lisenssillä, eikä se vaadi kehittäjän API-avainta tai käyttäjän tunnistautumista palveluun. Chatbot pyytää keskustelussa käyttäjältä lupaa yhdistää tietokantaan tiedonhakuja varten. Mikäli lupaa ei anneta, se käyttää vain sisäisiä lähteitä.

4.1.3 GPT:n antamien vastausten pituus ja Tokenit

GPT:t käsittelevät tekstiä palasina, joita kutsutaan tokeneiksi (tokens). Tokenit ovat tekstin perusyksiköitä, joita malli käyttää käsitellessään ja tuottaessaan tekstiä. Tokenit voivat olla yksittäisiä sanoja, sanojen osia, tai yksittäisiä merkkejä, kuten välimerkkejä tai erikoismerkkejä. Yksi tokeni vastaa keskimäärin noin neljää merkkiä tai 0,75 englannin kielen sanaa. (OpenAI Docs: Introduction 2024.)

Tokenisointimenetelmät ja merkkimäärät, joita GPT voi palauttaa vastauksena, voivat vaihdella eri GPT-versioiden välillä. Esimerkiksi GPT 3.5- ja GPT 4.0 -mallit pystyvät palauttamaan maksimissaan 4096 tokenia, joka vastaa noin 3000 englannin kielen sanaa. (OpenAI Docs: Models 2024.) Tokenien määrä vaikuttaa siis suoraan siihen, kuinka pitkiä vastauksia GPT pystyy antamaan käyttäjälle.

4.2 GPT:n julkaisu OpenAI Storeen

OpenAI Store on OpenAI:n kauppapaikka käyttäjien ja kehittäjien luomille GPT:lle. Toistaiseksi siellä olevien chatbottien käyttö on rajattu pois ilmaiskäyttäjiltä vain kuukausimaksullisen lisenssin haltijoille.

nimeämiskäytäntöihin ja tietosuojaan. Jos kehittäjä ei ole vahvistanut Builder-profiilia, GPT:n julkaisumahdollisuudet on rajattu vain omaan käyttöön tai linkillä jaettavaksi.

4.2.2 Julkaistun GPT:n hallinta ja käytön seuraaminen

Kustomoidun GPT:n hallinta ja käytön seuraaminen tapahtuu omasta ChatGPT Workspace -työtilasta. Sieltä on mahdollista tarkistaa ja säätää GPT:n asetuksia ja sen suoriutumista. Chats-palkki näyttää, kuinka monta kertaa GPT:tä on käytetty, ei tosin kovinkaan tarkasti. Vaihtoehdot tässä ovat 10+ ja 100+.

Kehittäjä voi myös lisätä sähköpostiosoitteensa Builder-profiiliin käyttäjäpalautetta varten. Tällöin GPT:n käyttäjillä on mahdollisuus lähettää palautetta suoraan kehittäjän sähköpostiin.

4.3 Projektissa esiin tulleet ongelmat ja jatkokehitys

Tämän opinnäytetyön puitteissa ei ollut mahdollista toteuttaa käyttäjäpalautteen keräämistä ja laajempaa testausta.

Kotiruokabotti ei osaa kääntää kaikkien ruokien nimiä suomeksi (esimerkkinä ”stir-fry”). Tämä voi johtua siitä, että kaikille ruoille ei löydy virallista suomenkielistä käännöstä. Joidenkin suomenkielisten sanojen taivutus tuottaa sille myös ongelmia.

Kotiruokabotti antaa ostoslistaan esimerkkinä oliiviöljyä 1 rkl, vaikka oliiviöljyä on pakko ostaa koko pullo. Kiinteissä aineksissa se kuitenkin osaa antaa ostettavaksi esimerkiksi 2 porkkanaa, vaikka reseptiin tarvittaisiinkin vain 1,5 porkkanaa raastettuna.

Puutteiden kartoitus ja keskustelualoitteiden parantaminen

Keskeistä jatkokehityksessä on chatbotin toiminnan nykytilan kartoittaminen, erityisesti puutteiden tunnistaminen vastauksissa ja ohjeiden epäselvyyksissä.

Kartoitus toteutettaisiin keräämällä palautetta käyttäjiltä. Puutteiden tunnistamisen jälkeen työ keskittyy ohjeistuksen täsmentämiseen. Chatbotin ohjeistusta täsmennetään kahdella tasolla: ensinnäkin parannetaan keskustelun aloituksia siten, että ne ovat sisällöllisesti relevantimpia. Toiseksi luodaan selkeämmät ohjeet chatbotille siitä, miten se voi jatkaa keskustelua kysymällä lisätietoja tai tarjoamalla syvällisempää tietoa aiheista, jotka kiinnostavat käyttäjää. Se sisältää esimerkiksi kysymysmallien kehittämistä, jotka auttavat chatbottia tunnistamaan, milloin ja millaista lisätietoa kysyä, sekä strategioita, jotka auttavat sitä pitämään keskustelua yllä kiinnostavalla ja mielekkäällä tavalla.

Kotiruokabotti olisi API:n avulla mahdollista yhdistää ruokakauppojen tietokantaan, josta se voi hakea yksittäisen aterian tai koko ostoslistan tuotteiden hinnat (ja mahdollisesti vertailla eri ruokakauppojen hintoja). Pidemmälle vietyinä sovellus voisi myös tilata tarvittavat tuotteet.

5 Yhteenveto

Kun tutustuin tekoälyyn ensimmäisen kerran, tehtävänäni oli auttaa kielimalleja luokittelemaan ihmisten sosiaaliseen mediaan lähettämien viestien sentimentejä eli sitä, onko viesti pohjimmiltaan tulkittavissa negatiiviseksi, positiiviseksi vai neutraaliksi. Silloin kielimallit eivät vielä kyenneet itsenäisesti tunnistamaan esimerkiksi viesteissä olevaa sarkasmia negatiivisuudeksi. Siitä on nyt noin kymmenen vuotta aikaa, ja sen jälkeen tekoäly on kehittynyt suurin harppauksin. Viimeisten kahden vuoden aikana kehitys on ollut jo niin huimaa, että on vaikea pysyä perässä.

Insinööriyötä tehdessäni pelkäsin, onko aihe jo pian auttamattomasti vanhentunut. Siksi halusin myös panostaa aiheen tietoperustaan, sillä koneoppimisen, syväoppimisen ja luonnollisen kielen käsittelyn perusteet kuitenkin pysyvät pohjimmiltaan samoina, vaikka niihin nojaava tekniikka laajojen kielimallien käsittelyssä kehittyikin koko ajan eteenpäin. Opinnäytetyön toiminnallinen osuus GPT:n kustomointiin liittyen on ollut tätä kirjoittaessa mahdollista OpenAI:n työkaluilla muutaman kuukauden ajan.

Myös kehotesuunnittelu on tärkeä osa tehokasta tekoälyn käyttöä. Vaikka ChatGPT kykenee generoimaan tekstiä, kuvia ja koodia lyhyidenkin ohjeiden perusteella, on oleellista hahmottaa, että se ei oikeasti ”ymmärrä” mitä käyttäjä haluaa sen tekevän vaan se toistaa opittuja malleja ja todennäköisyyksiä. Jos sille annetut ohjeet ovat epämääräisiä ja puutteellisia, ei lopputuloskaan ole toivotun kaltainen. Tämän vuoksi myös sen tuottamaan tiedon paikkansapitävyyteen tulee suhtautua kriittisesti.

Aihe herätti myös paljon jatkokysymyksiä generatiivisten tekoälymallien tulevaisuudesta, niiden tietosuojasta ja tietoturvan tasosta. Se, mitä kaikkea generatiivinen tekoäly mahdollistaa vuoden päästä tai kymmenen vuoden päästä, jää vain arvailujen varaan. Tekoälyn nopea kehitys tulee joka tapauksessa vaikuttamaan siihen, miten haemme ja käsittelemme tietoa.

Lähteet

Adiwardana, Daniel; Luong, Minh-Thang; So, David R.; Hall, Jamie; Fiedel, Noah; Thoppilan, Romal; Yang, Zi; Kulshreshtha, Apoorv; Nemade, Gaurav; Lu, Yifeng; Le, Quoc V. 2020. Towards a Human-like Open-Domain Chatbot. Verkkoaineisto < <https://arxiv.org/abs/2001.09977>>. Päivitetty 27.2.2020. Luettu 10.4.2024.

Aila, Timo; Karras, Tero, Laine, Samuli. 2018. A Style-Based Generator Architecture for Generative Adversarial Networks. Verkkoaineisto. <<https://arxiv.org/abs/1812.04948>>. Päivitetty 29.3.2019. Luettu 10.4.2024.

Alarcon, Nefi. 2019. NVIDIA's GauGAN Wins a 2019 Popular Science "Best of What's New Award". Verkkoaineisto. Nvidia. <<https://developer.nvidia.com/blog/nvidias-gaugan-wins-a-2019-popular-science-best-of-whats-new-award/>> Päivitetty 3.12.2019. Luettu 22.3.2024.

Awan, Abid Ali. 2023. Verkkoaineisto. Datacamp. <https://www.datacamp.com/blog/what-is-labeled-data>>. Luettu 14.4.2024.

AWS: What is transfer learning. Verkkoaineisto. Amazon AWS. < <https://aws.amazon.com/what-is/transfer-learning/>>. Luettu 12.3.2024.

Bilal, Ahmad. 2022. API Schemas and their Types. Verkkoaineisto. RapidApi. < <https://rapidapi.com/guides/api-schemas>>. Päivitetty 19.1.2022. Luettu 6.4.2024.

Blete, Marie-Alice & Caelen, Olivier. 2023. Developing Apps with GPT-4 and ChatGPT. E-kirja. O'Reilly Media Inc.

ChatGPT Pricing. 2024. Verkkoaineisto. OpenAI. <<https://openai.com/chatgpt/pricing>>. Luettu 23.4.2024.

Chowdhery, Aakanksha & Narang, Sharan. 2022. Pathways Language Model (PaLM). Verkkoaineisto. Google. < <https://research.google/blog/pathways-language-model-palm-scaling-to-540-billion-parameters-for-breakthrough-performance/>> Päivitetty 4.4.2022. Luettu 9.4.2024.

Collins, Eli & Ghahramani, Zoubin. 2021. LaMDA: our breakthrough conversation technology. Verkkoaineisto. Google. <<https://blog.google/technology/ai/lamda/>>. Päivitetty 18.3.2021. Luettu 7.4.2024.

Dhamani, Numa & Engler, Maggie. 2024. Introduction to Generative AI. E-kirja. Manning Publications.

Foster, David. 2023. Generative Deep Learning, 2nd Edition. E-kirja. O'Reilly Media Inc.

GPT-4 Technical Report. 2023. Verkkoaineisto. OpenAI. <<https://arxiv.org/abs/2303.08774>> Päivitetty 4.3.2024. Luettu 15.4.2024.

Hsiao, Sissie & Manyika, James. 2023. An overview of Bard: an early experiment with generative AI. Verkkoaineisto. Google. <<https://ai.google/static/documents/google-about-bard.pdf>>. Päivitetty 19.10.2023. Luettu 15.4.2024.

Hui, Jonathan. 2018. GAN: Why it is so hard to train Generative Adversarial Networks. Verkkoaineisto. Medium. <<https://jonathan-hui.medium.com/gan-why-it-is-so-hard-to-train-generative-adversarial-networks-819a86b3750b>> Päivitetty 21.6.2018. Luettu 18.3.2024.

Introducing ChatGPT. 2022. Verkkoaineisto. OpenAI. <<https://openai.com/blog/chatgpt>> Päivitetty 30.11.2022. Luettu 28.3.2024.

Introducing Gemini. 2023. Verkkoaineisto. Google. <<https://blog.google/technology/ai/google-gemini-ai/>>. Päivitetty 6.12.2023. Luettu 15.3.2024.

Introducing Meta Llama 3. 2024. Verkkoaineisto. Meta AI. <<https://ai.meta.com/blog/meta-llama-3/>> Päivitetty 18.4.2024. Luettu 20.4.2024.

JAMK: Syväoppiminen. 2024. Verkkoaineisto. JAMK oppimateriaalit. <<https://syvaoppiminen-ttow1400-3001.pages.labranet.jamk.fi/syvaoppiminen-materiaalit/>>. Luettu 8.4.2024.

Jung, Alexander. 2022. Machine Learning: The Basics. Singapore: Springer.

Knowledge in GPT's. 2024. Verkkoaineisto. OpenAI. <<https://help.openai.com/en/articles/8843948-knowledge-in-gpts>>. Luettu 11.4.2024.

Kämäräinen, Joni. 2023. Koneoppimisen perusteet. Tallinna: Gaudeamus Oy.

Llama 2: open source, free for research and commercial use. 2023. Verkkoaineisto. Meta AI. <<https://llama.meta.com/llama2/>>. Luettu 7.4.2024.

Nabi, Javaid. 2019. Recurrent Neural Networks (RNNs). Verkkoaineisto. Towards Data Science. <<https://towardsdatascience.com/recurrent-neural-networks-rnns-3f06d7653a85>>. Päivitetty 12.7.2019. Luettu 18.4.2024.

Ojanperä, Tero. 2023. Tekoälyn vallankumous: Käsikirja. Keuruu: Otavan Kirjapaino Oy.

Ojutkangas, Krista; Larjavaara, Meri; Miestamo, Matti; Ylikoski, Jussi. 2013. Johdatus kielitieteeseen. Helsinki: Sanoma Pro Oy.

OpenAI Docs: Introduction. 2024. Verkkoaineisto. OpenAI. <<https://platform.openai.com/docs/introduction>> Luettu 7.4.2024.

OpenAI Docs: Models. 2024. Verkkoaineisto. OpenAI. <<https://platform.openai.com/docs/models/gpt-3-5-turbo>> Luettu 7.4.2024.

OpenAPI Specification v. 3.1.0. 2021. Verkkoaineisto. OpenAPI Initiative. <<https://spec.openapis.org/oas/v3.1.0>> Luettu 8.4.2024

Phi, Michael. 2018. Illustrated Guide to LSTM's and GRU's. Verkkoaineisto. Towards Data Science. <<https://towardsdatascience.com/illustrated-guide-to-lstms-and-gru-s-a-step-by-step-explanation-44e9eb85bf21>>. Päivitetty 24.9.2018. Luettu 18.4.2024

Prompt Engineering. 2024. Verkkoaineisto. OpenAI. <<https://platform.openai.com/docs/guides/prompt-engineering>> Luettu 17.3.2024.

Solis, Dani. 2020. Transformer models: How did it all start? Verkkoaineisto. Towards Data Science. <<https://towardsdatascience.com/transformer-models-how-did-it-all-start-2e5b385ddd93>>. Päivitetty 13.8.2020. Luettu 28.3.2024.

Taulli, Tom. 2019. Artificial intelligence basics: a non-technical introduction, 4th Edition. E-kirja. Apress.

Transfer learning and fine-tuning. Verkkoaineisto TensorFlow. <https://www.tensorflow.org/tutorials/images/transfer_learning#summary>. Luettu 12.3.2024.

What is reinforcement learning. Verkkoaineisto. Amazon. <<https://aws.amazon.com/what-is/reinforcement-learning/>>. Luettu 15.4.2024.

