

Mitä tekoäly ja sen kehitys merkitsevät taloudelle ja tutkimukselle?

Muutamia näkemyksiä ja joitakin arvauksia

Ari Hyytinen

Suurten kieli- ja päättelymallien sekä tekoälyagenttien nopea kehitys kyseenalaistaa perinteiset käsitykset teknologisen kehityksen merkityksestä työelämälle ja taloudelle. Vaikka tekoälymallien suorituskyvyn rajat ovat edelleen epäselviä, niiden kyky käsitellä ja hyödyntää aiemmin ei-kodifioitavissa olevaa tietoa ja tuottaa uusia ideoita viittaa siihen, että tekoäly ja tekoälyagentit voivat toimia talouskasvun kiihdyttäjinä ja jopa itsenäisinä taloudellisinä toimijoina. Tämä kehitys nostaa esiin perustavanlaatuisia tutkimuskysymyksiä sekä työn luonteesta että uusien merkinamekanismien ja sääntelyn tarpeesta tulevaisuudessa. Epäselvää on esimerkiksi se, millaisia taitoja ja millaista osaamista työmarkkinoilla tarvitaan jatkossa.

Tekoälyn (*artificial intelligence*, AI) kehitys on ollut viime vuosina hyvin nopeaa. Tätä näkemystä tukevat sekä omakohtaiset arkihavainnot, markkinoille tulleiden uusien tekoälymallien ja niihin perustuvien tuotteiden ja palveluiden määrä että tekoälyyn liittyvien patenttien ja julkaisujen määrä (Douglas ja Verstyuk 2025).

Tekoälyllä viitataan laveasti tietokoneen ja ohjelmistojen – tietokonejärjestelmien – kykyyn suoriutua tehtävistä, joiden on perinteisesti ajateltu edellyttävän ihmisen kognitiivisia kykyjä. Nämä kyvyt tekevät mahdolliseksi tiedon vas-

taanottamisen, käsittelyn, tallentamisen, käyttämisen ja soveltamisen. Puheen-, tekstin- ja kuvantunnistus ja niiden tuottaminen, matemaattisten ja muiden (loogisten) ongelmien ratkaisu, uusien ideoiden tuottaminen sekä tilannekohainen oppiminen ja päätöksenteko eri muodoissaan ovat esimerkkejä tehtävistä, joista tekoäly on alkanut suoriutua yhä paremmin.

Jo tapahtuneen kehityksen valossa tuntuu luonteelta todeta, englantilaista runoilijaa ja kuvataiteilijaa William Blakea mukaillen, että se, mikä on nyt tekoälyn osalta jo todistettu, oli

KTT Ari Hyytinen (ari.hyytinen@hanken.fi) toimii taloustieteen professorina Hankenilla ja Helsinki GSE:ssä. Tämä kirjoitus perustuu keskeisesti mutta ei yksinomaan Taloustutkijoiden 41. kesäseminaarissa Jyväskylässä 11.6.2025 pitämäni plenum-esitelmään. Kiitän päätoimittaja Mikko Puhakkaa sekä Mika Malirantaa, Petri Rouvista, Julia Salmea, Juhana Vartiasta ja Joosua Virtasta kommentista kirjoitukseeni.

aikoinaan vain kuviteltua.¹ Tekoälyn nopea kehitys herättääkin erilaisia perustavanlaatuisia kysymyksiä teknologisesta tulevaisuudestamme ja tekoälyn vaikutuksista nyt ja jatkossa. Kuinka tekoäly vaikuttaa talouteen ja muokkaa yhteiskuntaa? Miten se muuttaa työmarkkinoita ja uudelleensuuntaa työn ja erilaisten inhimillisten taitojen ja kyvykkyyksien kysyntää? Entä miten tekoäly vaikuttaa siihen, miten yritykset organisoivat tuotannollista toimintaansa, miten erilaiset tuotantoketjut ja markkinat toimivat tulevaisuudessa tai miten tutkimusta ja keksintöjä tehdään jatkossa?²

Nämä kysymykset ovat ajankohtaisia, koska merkittävä osa erityisesti talouskasvun edellytyksiin vaikuttavasta taloudellisesta toiminnasta kehittyneissä maissa liittyy nykyisin tiedon hallintaan ja tietotyöhön (*knowledge work*; ks. Ide ja Talamas 2025). Kyse on eritasoisesta ja -luonteisesta asiantuntijatyöstä, jossa tieto on sekä keskeinen panos että lopputuote. Tietotyötä tekevät eivät ainoastaan käsittele olemassa olevaa tietoa vaan pyrkivät myös soveltamaan ja hyödyntämään sitä tarkoituksenmukaisesti ja luovat sen pohjalta täysin uutta tietoa. Tämänkaltaiset tehtävät ovat osa-alueita, joilla tekoäly suoriutuu yhä paremmin ja nopeammin. Jo vuosi sitten esitettiin arvio, että nykyiset tekoälymallit käsittelevät tietoa ja tuottavat tuloksia

10–100 kertaa ihmistä nopeammin (ks. esimerkiksi Amodei 2024).

Tekoälyn kehitys pakottaa kysymään myös uudenlaisia kysymyksiä, kuten mitä teknologisen singulariteetin mahdollisuudesta pitäisi ajatella ja onko siitä syytä huolestua.³ Teknologisella singulariteetilla tarkoitetaan hypoteettista hetkeä, jolloin tekoäly tekee mahdolliseksi erittäin nopean, mahdollisesti hallitsemattoman ja peruuttamattoman teknologisen kehityksen (Aghion, Jones ja Jones 2019, Nordhaus 2021, Jones 2024) – ehkä niin, että yhteiskunta ja sääntely eivät pysy kehityksessä mukana.

Ajatus tekoälyn kehityksestä tähän suuntaan ei ole uusi, sillä ”koneälyn” (*machine intelligence*) mahdollisuuteen viittasi jo Turing (1950) kysyessään, voiko (tieto)kone ajatella. Tekoälyn kykyä parantaa ja kehittää itseään ovat jo varhain pohtineet mm. Good (1965) ja Vinge (1993). Uusimpia tätä kysymystä tarkastelevia tutkimuksia ovat mm. Ishibashi ja muut (2025), jossa arvioidaan, voisivatko suuret kielimallit (*large language models*) eli LLM-mallit keksiä algoritmeja parantaakseen itseään ja Shafayat ja muut (2025), jossa kysytään, voivatko suuret päättelymallit (*large reasoning models*) eli LRM-mallit opettaa itse itseään.

¹ “What is now proved was once only imagined” (William Blake).

² Peltosen ja Silvon (2025) *Euro&Talous* -kirjoitus käsittelee monia samoja kysymyksiä kuin tämä kesäkuiseen plenum-esitelmääni perustuva kirjoitus, mutta heidän 11.8.2025 julkaistu katsauksensa kuvaa lisäksi monipuolisemmin ja tarkemmin useita viimeaikaisia tutkimuksia tekoälyn taloudellisista vaikutuksista ja merkityksestä. Muita kotimaisia katsauksia aihealueeseen ovat mm. Kaubanen ja muut (2023, 2024).

³ Sivuutan tässä kirjoituksessa pohdinnat siitä, voiko tekoälyn vääränlainen tai hallitsematon kehitys johtaa tulemiin, jotka vaarantavat myös ihmiskunnan tulevaisuuden; ks. Jones (2024) ja viitteet siinä.

1. Kuinka suuret kieli- ja päättelymallit toimivat?

Perusmallit tai perustamallit (*foundation models*) ovat tyypillisesti parametrimäärällä mitattuna suurikokoisia ja monikerroksisia syviä neuroverkko-malleja, jotka on koulutettu valtavalla ja monipuolisella aineistolla. Se, että mallin parametrit on sovitettu hyvin laajoihin aineistoihin perustu-

en ei tarkoita, että malli on valmis käytettäväksi. Niitä räätälöidään ja sopeutetaan (esi)koulutuksen jälkeen lisää siten, että ne voivat suoriutua mitä erilaisimmista tehtävistä. Koulutettuja perustamalleja voidaan hienosäätää tai mukauttaa toisin sanoen tiettyihin käyttötarkoituksiin, kuten luonnollisen kielen käsittelyyn tai kuvanmuodostukseen. Tällaiset mallit voivat toimia pohjana monille muille tekoälysovelluksille (Laatikko 1).

Laatikko 1 – Generatiivinen tekoäly

Yleisemmin luonnollista kieltä (tekstiä), kuvia, videoita ja ääntä tuottavia malleja kutsutaan generatiiviseksi tekoälyksi (*generative artificial intelligence*). Nämä mallit ovat tyypillisesti olleet erikoistuneita siten, että niillä voidaan käsitellä, muokata ja tuottaa (pääosin) vain tietynlaista sisältöä, kuten esimerkiksi tekstiä (GPT-4, Claude Opus, Mistral) tai kuvia (DALL-E, Midjourney, Stable Diffusion). Rajat erilaisten sisältöjen välillä ovat kuitenkin hämärtyneet asteittain. Viime aikoina on kehitetty ns. suuria multimodaalimalleja (*large multimodal model*), jotka voivat tuottaa ja muokata sekä tekstiä, kuvia, ääntä että muunlaista sisältöä. Ne toimivat pitkälti samoin periaattein kuin erilaiset luonnollisen kielen tuottamiseen räätälöidyt kielimallit, mutta aineisto on muutettu vektorimuotoon niin, että useita eri aineistomuotoja voidaan käyttää yhden ja saman mallin kouluttamiseen.

Nykyisen tekoälykehityksen keskiössä ovat erityisesti suuret kielimallit eli LLM-mallit. Ne ovat monikerroksisia syviä neuroverkkoja, jotka on koulutettu valtavilla tekstimäärillä, joita käytetään luonnollisen kielen käsittelyyn ja jotka kykenevät tuottamaan uutta tekstiä annetun syötteen perusteella. Niitä on myös opetettu toimimaan ihmisten kanssa ns. ohjepohjaisella koulutuksella (*instruction tuning*), jossa mallia koulutetaan lisää mm. valittujen syöte-vastaus-

parien avulla.⁴ LLM-mallien suoriutuskykyä ja soveltuvuutta erilaisiin tehtäviin voidaan parantaa yleisemmin ns. hienosäädön (*fine-tuning*) avulla.

⁴ *Instruction tuning* -termi tarkoittaa toisin sanoen kielimallin lisäopettamista siten, että se osaa paremmin seurata käyttäjän sille antamia ohjeita ja vastata niihin. Näin perusmalleja muokataan toimimaan paremmin ihmisten kanssa, esimerkiksi miten malli käyttäytyy inhimillisestä vuorovaikutusnäkökulmasta ja kuinka se vastaa käyttäjien esittämiä mahdollisesti epäeettisiin kysymyksiin.

Kielimallien toiminta perustuu siihen, että luonnollinen kieli (teksti) jaetaan tavuiksi tai tarkemmin sanoen merkkijonoiksi (*token*). Kielimallien ns. transformer-arkkitehtuureihin sisältyvä huomiointimekanismi tekee mahdolliseksi sen, että malli voi työstää merkkijonoista koostuvia syötteitä rinnakkain – eli malli voi käsitellä osia pitkästäkin tekstistä tiettyssä mielessä kokonaisuutena (Vaswani ja muut 2017). Kun merkkijonoja ei työstetä yksi kerrallaan (autoregressiivisesti), niille muodostuu konteksti, kuten esimerkiksi tietylle sanalle asiayhteys, jossa se tekstissä esiintyy. Tämä ominaisuus tarkoittaa, että malli voi tunnistaa monimutkaisiakin kielellisiä riippuvuuksia ja rakenteita ja että se onnistuu tuottamaan esimerkiksi siltä kysyttyihin kysymyksiin pitkiä, johdonmukaisia – tai ainakin siltä kuulostavia – vastauksia.

Hieman yksinkertaistaen voidaan sanoa, että teknisesti LLM-mallit ovat luonnolliseen kieleen sisältyvien tilastollisten säännönmu-

kaisuuksien ja rakenteiden tunnistajia. Opetusvaiheessa niille pyritään opettamaan todellinen mutta tuntematon kielen jakauma, $p_{data}(\cdot)$, soveltamalla mallin jakauma, $p_{\theta}(\cdot)$, käytettävissä olevaan aineistoon (ks. Nie ja muut 2025, sekä McCoy ja muut 2024). Nämä valtavaan tekstiaineistoon sovitettut mallit tuottavat vastauksia eri tavoin, mikä usein tarkoittaa tilastollisesti todennäköisimmän seuraavan merkkijonon (”sanan”, ”tekstin”) ennustamista opetusdatasta opittujen säännönmukaisuuksien perusteella (ks. Laatikko 2). Tämän ennustamisominaisuuden ansiosta LLM-mallit pystyvät käsittelemään ja tuottamaan luonnollista kieltä.⁵ Koska luonnollisessa kielessä on paljon ja erilaisia säännönmukaisuuksia – kuten ennustettavissa olevia rakenteita ja muotoiluja – LLM-mallien avulla voidaan tuottaa luontevasti uutta tekstiä, kääntää tekstiä kielestä toiseen ja tehdä tiivistelmiä. Se, miten tämä tarkalleen ottaen tapahtuu, riippuu mallista.

⁵ Perinteisten LLM-mallien toimintaperiaate eroaa selvästi esimerkiksi ns. diffuusiomalleista (Yang ja muut 2023). Diffuusiomallit ovat syvään oppimiseen perustuvia generatiivisia malleja. Toisin kuin autoregressioon perustuvat LLM-mallit, nämä mallit lisäävät aineistoon satunnaista kobinaa, jonka jälkeen malli ”kääntää prosessin” luodakseen uutta dataa (vastauksen) kobinalla täydennetystä aineistosta. Ne siis luovat uutta dataa muuntamalla satunnaisen kobinan väbitellen halutunlaiseksi dataksi, kuten kuviksi tai ääniksi. Tämä kyky perustuu siihen, että ne oppivat ”kääntämään kobinan lisäysprosessin”.

Laatikko 2 – Kielimallien toimintaperiaate

LLM-mallit ovat tilastollisia malleja. Yksinkertaisimmillaan LLM-malli toimii siten, että se antaa vastauksenaan todennäköisimmän merkkijonon annettuna syöte, joka sille on annettu. Pidemmässä vastauksissa seuraavan merkkijonon ennusteen perusteena on alkuperäinen syöte ja siihenastinen mallin tuotos (ts. ei pelkkä syöte). Ennen kunkin merkkijonon (vastauksen) antamista malli tuottaa useita vastausvaihtoehtoja, joille kullekin lasketaan esiintymistodennäköisyys. Tämä on tulkittavissa todennäköisyydeksi, että vastaus on opetusaineistosta opittujen säännönmukaisuuksien valossa ”oikein”. LLM-malli pyrkii toisin sanoen maksimoimaan $Pr[\text{vastaus} \mid \text{syöte}]$ eli tietyn merkkijonon (sanan) todennäköisyyden ehdolla tekstisyöte.

Bayesin säännön mukaan $Pr[\text{vastaus} \mid \text{syöte}] = Pr[\text{syöte} \mid \text{vastaus}] \times Pr[\text{vastaus}]$, joten LLM-mallin tuottamaan ennusteeseen vaikuttaa siis vastauksen ei-ehdollinen todennäköisyys, $Pr[\text{vastaus}]$. LLM-malleilla on tästä johtuen taipumus antaa vastauksenaan merkkijonoja (sanoja, tekstiä), joilla on suuri ei-ehdollinen todennäköisyys esiintyä opetusaineistossa (McCoy ja muut 2024). Tämä puolestaan tarkoittaa, että LLM-malleilla on taipumus toimia paremmin tilanteissa, joissa oikean vastauksen (ei-ehdollinen) todennäköisyys on suuri ja vastaavasti huonommin tilanteissa, joissa oikean vastauksen (ei-ehdollinen) todennäköisyys on pieni.

Tärkeää on huomata se, että tilastollisesti todennäköisimmän seuraavan merkkijonon (”sanan”) ennustaminen opetusdatasta opittujen säännönmukaisuuksien perusteella ei ole automaattisesti sama asia kuin totuudenmukaisen (”oikean”) vastauksen esittäminen. Mikäli opetusaineistossa esiintyy johonkin tiettyyn asiaan liittyen merkittävässä määrin väärinkäsityksiä, LLM-mallit saattavat jopa päätyä vahvistamaan niitä.

Kuluneen reilun vuoden aikana on LLM-mallien pohjalta kehitetty suuria päättelymalleja eli LRM-malleja. Näitä malleja on pyritty kehittämään erityisesti monimutkaisempien ongelmien ratkaisuun ja päättelytehtäviin. Mallin päättelykyvyllä tarkoitetaan erilaisten loogisten tekniikoiden hyödyntämistä, kuten kysymysten ja vastausten pilkkomista peräkkäisiin vaiheisiin, johtopäätösten tekemistä vaiheittain ja vastausten (ennustetun seuraavan sanan) mukauttamista ”mallin tekemän itsereflektioon” perustuen. LRM-mallit pystyvät esimerkiksi jakamaan ongelman pienempiin vaiheisiin ketjupäättelyn (*chain-of-thought*) avulla (Wei et al.,

2022). LRM-mallit suorittavat usein myös ennen vastaamista ylimääräisen, aikaa vievän laskentavaiheen (*test-time compute step*), minkä ajatellaan johtavan parempiin vastauksiin. Tavallaan kyse on ongelman tai mallille esitetyn kysymyksen pilkkomisesta osiin mallin ”sisällä”, ennen varsinaisen vastauksen antamista.⁶

⁶ Tämä ”testiajan laskenta” on tekoälymallin käyttämä ylimääräinen laskentateho ja aika, jonka se käyttää tuottaessaan vastauksen tai ratkaisun. Idea on, että tämä ylimääräinen laskenta antaa mallin ”ajatella” - ts. päätellä tekstiä käsittelemällä - pidempään ja että tämä lisäpäättely on hyödyksi monimutkaisten ongelmien ratkaisemisissa.

Sekä LLM- että LRM-mallien kehitykseen liittyvä tärkeä käsite on ns. emergentit ominaisuudet. Tämä käsite viittaa ennakoimattomiin suorituskyyhiin, jotka ilmestyvät odottamatta mallin koon, laskentatehon tai koulutusdatan kasvaessa. Tällaiset kyvyt eivät ole nimenomaisesti malliin opetusvaiheessa ohjelmoituja tai tavoiteltuja eikä niitä havaita pienemmissä malleissa (Berti et al., 2025). Esimerkiksi suurempi LLM-malli saattaa yllättäen kyetä ratkaisemaan tietynlaisia matemaattisia ongelmia, vaikka sitä ei olisi nimenomaisesti tätä varten opetettu. Määrällinen skaalaus opetusvaiheessa voi siis johtaa merkittäviin laadullisiin muutoksiin tekoälymallien suorituskyvyyssä.

Sekä LLM- että LRM- mallien keskeinen haaste on se, että ne jäljittelevät ja tunnistavat opetusaineistoon sisältyviä rakenteita ja säännönmukaisuuksia ilman todellista ymmärrystä. Vaikka kysymys olisi monimutkaisempi, ne tuottavat vastauksensa malliennusteisiin pohjautuen eli siis sekä opetusaineistosta opittujen säännönmukaisuuksien että syötteisiin sisältyvien sisältöjen pohjalta. Tämä johtuu siitä, mihin tarkoitukseen ja miten nämä mallit ovat alun perin kehitetty (McCoy ja muut 2024). LLM-malleja onkin kutsuttu myös ”stokastisiksi papukaijoiksi” (ks. Bender ja muut 2021).

Vaikka LRM-mallien toimintaperiaatteessa on kiinnitetty erityistä huomiota mallin päätelykykyyn, niiden tuottamien vastausten luotettavuus ja osuvuus ovat edelleen hyvin epävarmalla pohjalla (Shojaee ja muut 2025). Tutkimuksissa on noussut esiin mm. huolia LRM-mallien päätelykyvyn ristiriitaisuuksista eri yhteyksissä (Kambhampati 2024, Kambhampati ja muut 2025). Myös LRM-mallien päätelyprosessi ja lopullinen vastaus voivat olla ristiriidassa keskenään. On siis vielä epäselvää, kuinka mer-

kityksellistä ”päättelyä” tai ”ajattelua” näissä LRM-malleissa tapahtuu.⁷

Toinen, yllä sanottuun kiinteästi liittyvä haaste neuroverkkoihin perustuvissa LLM- ja LRM-malleissa on se, että ne pystyvät tekemään yleistyksiä (*generalizations*) ja tarjoamaan oikeita ja perusteltuja vastauksia lähinnä vain niiden opetuksessa käytetyn opetusaineiston jakauksen (*training distribution*) perusteella. Tämä tarkoittaa sitä, että ne osaavat käsitellä ja hyödyntää sellaista uutta tekstiä ja aineistoa, joka muistuttaa riittävällä tavalla opetusaineistoa ja siitä jo opetusvaiheessa opittua. Kun mallit käsittelevät opetusaineiston jakautuman ulkopuolista tekstiä ja aineistoa – eli esimerkiksi sellaista tietoa, jota ne eivät ole nähneet aiemmin – niiden kyky yleistää, päätellä ja tarjota oikeita ja perusteltuja vastauksia heikkenee (Marcus ja muut 1999, Marcus 2022, Kambhampati 2024, Kambhampati ja muut 2025). Tätä ongelmaa kutsutaan jakauman ulkopuoliseksi yleistämiseksi (*out-of-distribution generalization*): Pystyvätkö suuret kieli- ja päätelymallit yleistettävään päätelyyn ja ongelman ratkaisuun? Vai perustuuko niiden suorituskky hyvin monimutkaisella tavalla edelleen opetusaineistosta opittuihin säännönmukaisuuksiin?

2. Tekoälyagentit taloudellisina toimijoina?

Tekoälyä voidaan tarkastella perinteisen taloustieteen näkökulmasta yleiskäyttöisenä teknologiana (*general purpose technology*), joka leviää laajalle talouteen ja joka kehittyessään lisää ta-

⁷ Esimerkkejä tällaisista malleista ovat mm. OpenAI:n o3, Claude 3.7 Sonnet Thinking, DeepSeek-R1, ja Gemini 2.5 Flash (”with thinking budget”).

louden kokonaistuottavuutta ja siten pitkän aikavälin kasvuedellytyksiä (Acemoglu 2025). Tämän näkökulman mukaan tekoälyn ja sen vaikutukset vastaisivat ainakin periaatteellisella tasolla esimerkiksi sähkön, tieto- ja viestintäteknologioiden ja automaation yleistymistä ja niiden tuottavuusvaikutuksia.

Vaikka merkittäviä käytännön sovelluksia ollaan toistaiseksi vasta kehittämässä, ns. tekoälyagenttien (*artificial agents*) kehitys kuitenkin kyseenalaistaa näkemyksen, että tekoäly voidaan suoraviivaisesti rinnastaa aikaisempiin yleiskäyttöisiin teknologioihin. Kehitteillä olevat tekoälyagentit eroavat esimerkiksi perinteisestä sääntöpohjaisesta automaatiosta siinä, että ne voivat asettaa toiminnalleen välitavoitteita ja mukauttaa toimintaansa ilman jatkuvaa ihmisen ohjausta. Ne voivat myös itsenäisesti hyödyntää erilaisia työkaluja, muistijärjestelmiä ja havainnointimoduuleja (Wang et al., 2024; Krishnan, 2025; Ganji ja Zarifhonorvar 2025). Autonomiset tekoälyagentit toimivat havainnoimalla ympäristöään, käsittelemällä tietoa ja erilaisia syötteitä, tekemällä suunnitelmia ja päätöksiä, käyttämällä työkaluja tarpeen mukaan ja toteuttamalla sitten nämä suunnitelmat saavuttaakseen esimerkiksi syötteessä asetetut tavoitteet.


Periaatteessa tekoälyagentit voisivat toimia täysin autonomisesti, mutta niin pitkällä ko. teknologia ei vielä ole. Niitä on tällä hetkellä parempi ajatella semi-itsenäisinä toimijoina, jolloin ihminen hyväksyy päätökset eri vaiheissa ja tekoälyagentti voi edetä ja jatkaa toimintaansa vasta tällaisen hyväksynnän jälkeen.

Kuvio 1 havainnollistaa yksinkertaistettua tekoälyagenttiarkkitehtuuria. Kuten kuviosta nähdään, tekoälyagentit ovat järjestelmiä, jotka

koostuvat useista komponenteista. Näitä komponentteja ovat mm. syötteitä ja muuta aineistoa vastaanottava ja tulkitseva havaintomoduuli, päättelyä ja päätöksiä tekevä kieli- tai päättelymalli, sekä ko. mallien saatavilla olevat tietovarannot, muistijärjestelmät ja toimenpide ja työkalumoduulit (Krishnan 2025; ks. myös Chan ja muut 2025).

Esimerkiksi yrityksen hankinta- ja ostosavustajana toimiva tekoälyagentti hyödyntää ensin havainto- ja päättelymoduuleja, jotka käsittelevät hankintapyynnön (esim. ”etsi paras asiakastietojärjestelmä yrityksemme käyttöön”) ja analysoi tietoa ko. tuotteita tarjoavien yritysten kotisivuilta ja saatavilla olevista järjestelmä-arvoista ja -kuvauksista. Tekoälyagentti voi käyttää sille saataville annettuja työkaluja (ulkoisia järjestelmiä), kuten toimittajien verkkosivujen rajapintoja hankkiessaan (reaaliaikaista) lisätietoa hankintasuunnitelman laatimiseksi ja saatavilla olevien soveltuvien vaihtoehtojen selvittämiseksi. Sen tietovarantoon on voitu tallentaa yrityksen asiantuntijoiden tuottamaa tarkentavaa tietoa mm. hankittavan järjestelmän toivottavista teknisistä ominaisuuksista ja yrityksen muista tietojärjestelmistä. Riippuen tekoälyagentin tarkemmasta arkkitehtuurista sen toimintakyvyt saattavat tehdä mahdolliseksi myös hankinnan käynnistämisen itsenäisesti ilman ihmisen osallistumista. Tällöin se mm. arvioisi hankintaehdotukset, järjestäisi ne paremmuusjärjestykseen sekä laatisi ja lähettäisi tarjouspyynnöt. Kenties joskus tulevaisuudessa hankinta- ja ostosavustajana toimiva tekoälyagentti voi tehdä myös lopullisen hankintapäätöksen ja toteuttaa hankinnan.

Kuvio 1: Tekoölyagentin yksinkertaistettu arkkitehtuuri (mukaillen Krishnan 2025)



Vaikka vielä tekoölyagentit eivät kykene suoriutumaan kovin monimutkaisista ja vaativista tehtävistä ja ovat alttiita virheille, niiden nopea kehitys herättää kysymyksen, tulisiko niitä tarkastella taloustieteen näkökulmasta jonkinlaisina itsenäisinä taloudellisinä toimijoina (*economic agents*)? Tätä ovat esittäneet mm. Immorlica ja muut (2024), ja Ide ja Talamas (2025). Gillian K. Hadfieldin ASSA-paneelissa 2025 San Franciscossa pitämä puheenvuoro kiteyttää hyvin ajatuksen tekoölyagenteista taloudellisinä toimijoina:

”Kaikessa tässä on kyse autonomiasta [...]. Mieti, mitä se tarkoittaa: [tekoölyagentit voisivat] tehdä liiketoimia, solmia sopimuksia, palkata ihmisiä, suunnitella tuotteita, asettaa tuotteille hintoja, mainostaa ja tehdä kaikkea tällaista. Siksi mielestäni on todella tärkeää, että muutamme hieman ajatteluamme. [...] Emme ajattele sitä vain teknologiana tai työkaluna, vaan pikemminkin uudenlaisena taloudellisenä toimijana.”⁸

Kehittyessään autonomiset tekoölyagentit voivat lopulta käyttäytyä kuten perinteiset taloudelliset toimijat, jotka tekevät itsenäisesti päätöksiä ja valintoja preferensseihinsä ja käytettävissä olevaan tietoon pohjautuen, ottaen huomioon kussakin päätöksentekotilanteessa käytettävissä olevat valinta- ja toimintamahdollisuudet (Immorlica ja muut 2024, Raman ja muut 2024). Tällaisten kehittyneempien tekoölyagenttien keskeinen ominaisuus tulee olemaan paitsi niiden kyky toimia itsenäisesti, myös niiden kyky oppia ja muuttaa ja sopeuttaa toimintaansa erilaisissa ympäristöissä.

Tämän näkökulman myötä nousee esiin monia uusia tutkimuskysymyksiä: Miten tekoölyagentit vaikuttavat työmarkkinoiden toimintaan ja tasapainoon? Entä miten kannustinongelmat ja organisaatiot muuttuvat, kun tehtäviä delegoidaan tekoölyagenteille? Miten tekoölyagentit vaikuttavat tuotannon organisointiin, arvoketjuihin ja yritystoimintaan? Millaisia uusia markkinamekanismeja syntyy, kun markkinoilla toimii sekä ihmisiä että tekoölyagenteja? Entä millaista uutta sääntelyä tarvitaan, jos autonomiset tekoölyagentit yleistyvät (Cohen ja muut 2024)? Kuka voi vaikuttaa preferensseihin, joita tekoölyagenteilla on tai joita ne mukailevat päätöksiä ja valintoja tehdessään?

⁸ Lainausta on poimittu Iden ja Talamasin (2025) artikkelista ja se on kirjoittajan vapaa suomennos.

3. Tekoäly tutkimuksessa ja talouskasvun kiihdyttäjänä

Yllä esitetyn jatkoksi on luontevaa kysyä, miten tekoäly ja tekoälyagentit vaikuttavat talouskasvuun? Kun tekoälyn vaikutuksia on arvioitu samoista lähtökohdista kuin miten automaation ja muiden aiempien teknologioiden merkitystä on tarkasteltu, eri tutkimuksissa on saatu varsin erilaisia tuloksia; ks. Peltonen ja Silvo (2025) ja Kuusi (2025), sekä näistä tutkimuksista löytyvät kirjallisuusviitteet.⁹ Kuten Peltonen ja Silvo (2025) toteavat, erot liittyvät tehtyihin oletuksiin ja painotuksiin mm. koskien sitä, rajoitustaanko tarkasteluissa arvioimaan tällä hetkellä käytettävissä olevien tekoälyteknologioiden vaikutuksia vai sisältyikö laskelmiin näkemyksiä ja alustavia arvioita myös siitä, kuinka niiden ennakoidaan kehittyvän jatkossa.

Hieman toisenlainen näkökulma tekoälyn kasvuvaikutuksiin saadaan, kun otetaan huomioon se, että tekoälyn avulla on jo jossain määrin pystytty – ja saatetaan jatkossa pystyä vielä selvästi nykyistä enemmän – automatisoimaan uusien ideoiden tuottamista. Tekoäly on tästä näkökulmasta tarkasteltuna keksintö menetelmästä, kuinka keksintöjä tehdään (*invention of a method of inventing*; Griliches 1957); se on siis keksintö, joka nopeuttaa teknologista kehitystä parantamalla ideoiden tuottamisprosessia.

⁹ Kuusi (2025) on hiljattain arvioinut monen sektorin kasvumallin avulla (generatiivisen) tekoälyn kasvuvaikutuksia Suomessa. Hän korostaa malliepävarmuuden ja panos-tuotos-rakenteen kerrannaisvaikutusten merkitystä mallin tuotamille määrällisille arvioille ja malliennusteille. Kuusen (2025) mukaan laskelmien perusskenaarioissa tekoälyn käyttöönotto lisäisi vuosittaista talouskasvua vajaan 0,5 prosenttiyksikköä, kun arvio esitetään seuraavalle kymmenelle vuodelle.

Mikäli tekoäly kykenee nopeuttamaan uusien ideoiden tuottamista, talouskasvua perinteisesti rajoittanut tekijä – eli tutkijoiden ja kehittäjien rajallinen määrä ja siten rajallinen inhimillisen osaamisen ja älykkyyden tarjonta – voi poistua, tai ainakaan se ei ole yhtä lailla rajoittava tekijä kuin aiemmin (Jones 2024). Tämän seurauksena teknologinen kehitys saattaa kiihtyä huomattavasti, mikä voi potentiaalisesti johtaa tässä kirjoituksessa jo aiemmin mainittuun teknologiseen singulariteettiin (Davidson, 2021; Erdil ja Besiroglu, 2023; Nordhaus, 2021).

Tämänkaltainen kehitys voisi johtaa nykyisen yhteiskunnan ja talouden ja niiden rakenteiden ennakoimattomaan ja mahdollisesti hyvin perustavanlaatuiseseen muutokseen. Niin voisi käydä, jos informaatioteknologian ja tekoälyn nopea kehitys ylittää jonkin rajan, jonka jälkeen yhä kiihtyvä teknologisten parannusten toisiaan vahvistava kierre nopeutuu (Nordhaus 2021; ks myös Aghion, Jones ja Jones 2019, Trammell ja Korinek 2023, Jones 2024).

Tekoälyn kyky tuottaa uusia ideoita ja innovaatioita perustuu osittain siihen, että uusilla ideoilla ja innovaatiolla on taipumus olla kombinatorisia. Kombinatorinen idea tai innovaatio syntyy, kun olemassa olevia ideoita uudelleen käytetään ja yhdistellään ja kun tämän myötä onnistutaan luomaan uusia teknologioita (Weitzman 1998; Arthur, 2009). Tekoälyn voidaan ajatella nopeuttavan nimenomaan tätä prosessia. Yksi syy tähän on se, että luonnollista kieltä käsitellessään ja vastauksia tuottaessaan ne päätyvät monimutkaisella tavalla nimenomaan yhdistelemään opetusaineistoista löytyviä käsitteitä, tuloksia, ideoita ja rakenteita.

Tekoäly voi nopeuttaa tieteellistä tutkimusta myös automatisoimalla tieteellisten yhteenveitojen ja katsausten tekoa, hypoteesien ja mallien luomista, datan kokoamista ja data-analyysia

(Cockburn ja muut 2019, Chang ja Li 2025). Se voi myös auttaa automatisoimaan uudenlaisten, ideoiden toimivuutta selvittävien kokeiden ja pilottitestien suunnittelua.¹⁰

4. Millaista osaamista tarvitaan tekoälyn aikakaudella?

Perinteisestä näkökulmasta tarkasteltuna tekoälyn kehitys voi vaikuttaa työmarkkinoihin ja eri toimialoihin monin tavoin (Acemoglu 2025). Nämä vaikutukset riippuvat siitä, miten paljon ja minkälaista päällekkäisyyttä on esimerkiksi niiden taitojen, joita tyypillisesti vaaditaan tietyn toimialan työtehtävissä ja tekoälyn teknisten suorituskkykyjen välillä. Kauhanen ja muut (2024) toteavat kirjallisuuden pohjalta, että tekoälypohjaiset työkalut vaikuttaisivat nostavan työn tuottavuutta ja laatua erityisesti, kun niitä hyödynnetään tavanomaisissa, melko kaavamaisissa työtehtävissä.¹¹

Jotkin tutkimustulokset viittaavat siihen, että tekoäly hyödyttää suhteellisesti enemmän niitä, joilla on vähiten tietoa ja vähentää siten suoriutumiseen liittyvää epätasa-arvoa (ks. esimerkiksi Caplin ja muut 2024). Toisaalta on myös näyttöä siitä, että tekoäly täydentää korkeasti koulutettujen tietotyötä tekevien osaa-

mista samalla, kun se korvaa heidän vähäisemmin koulutettuja vastineitaan (ks. mm. Berger et al., 2024). Lisäksi on näyttöä, että tekoälyn käyttöönotto lisää johtamistaitojen ja -roolien kysyntää ja että se muuttaa johtajilta vaadittavia taitoja, lisäten tarvetta yhteistyökyvyille ja luovuudelle sekä kyvyille johtaa sidosryhmiä ja ymmärtää data-analyysyjä (Alekseeva ja muut 2024).

Toistaiseksi on vaikea ennustaa, miten tekoälyn kehitys vaikuttaa työmarkkinoilla ja minkälaisia taitoja tarvitaan jatkossa. Joitain näkemyksiä voidaan kuitenkin esittää taloustieteellisten tutkimusten pohjalta, jotka perustuvat kahteen erilaiseen analyttiseen lähestymistapaan.

Ensimmäinen näistä kahdesta lähestymistavasta on erilaisia työtehtäviä korostava malli (*task-based model*), jossa työntekijän toimenkuvan tulkitaan koostuvan erilaisista työtehtävistä tai -vaiheista (Acemoglu ja Autor 2011, Autor 2013). Toinen lähestymistapa korostaa työntekijöiden ja työtehtävien organisoitumista tietoperusteisesti ns. osaamishierarkioiksi (*knowledge hierarchies*) riippuen työntekijöiden kyvyistä ratkoa erilaisia ongelmia (ks. Garicano 2000, Garicano and Rossi-Hansberg 2004, Antras ja muut 2006, Fuchs ja muut 2015). Malli ennustaa, että kyvykkäämmät ongelmanratkaisijat päätyvät hierarkiassa korkeammalle, käsittelemään tuotantotoimintaa liittyviä poikkeustapauksia ja ratkomaan vaikeampia ongelmia. Ide ja Talamas (2025) hyödyntävät tätä lähestymistapaa arvioidessaan, miten tekoäly vaikuttaa työmarkkinoihin ja tuotannollisen toiminnan organisoitumiseen, erityisesti tietointensiivisillä toimialoilla.

¹⁰ *Se, miten tekoäly on vaikuttanut tai vaikuttaa nimenomaan taloustieteelliseen tutkimukseen, on oma kysymyksensä, joka ansaitsee erillisen tarkastelun; Korinek (2023, 2024, 2025) tarjoavat aiheeseen erinomaisen johdannon ja katsauksen.*

¹¹ *Peltosen ja Silvon (2025) katsaus käy tarkemmin läpi tätä kirjallisuutta ja siinä saatuja tuloksia, samoin kuin tarkasteluja, joissa arvioidaan erilaisten toimialojen ja työtehtävien altistumista tekoälyn vaikutuksille; ks. myös Kauhanen ja muut (2023) ja Kauhanen ja Rouvinen (2025).*

4.1. Taitojen komplementaarisuuden merkitys inhimillisissä taito- ja osaamiskokonaisuuksissa

Tekoälyn kyvyt voivat olla työtehtäviä korostavassa mallissa joko ihmisen kykyjä korvaavaa tai niitä täydentävää (Acemoglu ja muut 2025, Acemoglu 2025; ks. myös Peltonen ja Silvo 2025, Kuvio 2). Tekoäly voi eri työtehtävissä laajentaa automaatiota tehtäviin, joita ihmiset ovat aiemmin suorittaneet (syrjäytysvaikutus), kuten kielten kääntämiseen ja asiakaspalveluun, sekä syventää automaatiota pääomavaltaisissa tehtävissä (syvenemisvaikutus). Lisäksi tekoälyllä voi olla kykyjä, jotka täydentävät työntekijöiden osaamista ja taitoja. Tällainen komplementaarisuus lisää ko. työntekijöiden tuottavuutta (tuottavuusvaikutus). Tekoäly voi synnyttää myös kokonaan uusia työtehtäviä, kuten tekoälyn tehokkaaseen hyödyntämiseen liittyviä asiantuntija-tehtäviä (uudistamisvaikutus). Tekoäly ei toisin sanoen ainoastaan korvaa ihmisen työpanosta, vaan myös muuttaa ja luo uudenlaista työtä.

Yksi keskeinen työtehtäviä korostavasta mallista kumpuava ajatus on, että inhimillisiä taitoja (kyvykkyyksiä) hyödynnetään harvoin yksin siinä mielessä, että useimmat tehtävät ja työt edellyttävät useiden taitojen hyödyntämistä yhtä aikaa. Tällöin kykyyn suoriutua erilaisista työtehtävistä vaikuttaa oleellisesti henkilön erilaisista taidoista koostuva taito- ja osaamiskokonaisuus (*skill bundle*; Acemoglu ja Autor 2011; ks. myös Hosseinion ja muut 2025). Tällä on kolme seurausta (Stephany ja Teutloff 2024):

- Ensinnäkin, kun tarkastellaan tiettyä taitoa osana henkilökohtaista taito- ja osaamiskokonaisuutta, sen merkitykseen, hyödyllisyyteen ja arvoon työmarkkinoilla vaikuttavat sekä se, kuinka taito- ja osaamiskokonaisuuteen sisältyvät muut taidot täydentävät

sitä, että se, kuinka ko. taito täydentää näitä muita taitoja. Lisäksi tietyn taidon arvoon työmarkkinoilla vaikuttaa se, miten arvokkaina sitä täydentäviä muita taitoja pidetään työmarkkinoilla. Vaikka nämä havainnot pätevät yleisemminkin, on ajateltavissa, että osaamiskokonaisuuksien ja niihin sisältyvien taitojen komplementaarisuuden merkitys korostuvat tekoälyn kehityksen myötä.

- Toiseksi, kun tekoälyä hyödynnetään yhä laajamittaisemmin, tietyn inhimillisen taidon merkitys ja hyödyllisyys – ja siten arvo – työmarkkinoilla riippuu siitä, miten tekoälyn suorituskyky täydentää sitä. Tämä viittaa siis yllä mainittuun ihmisen ja tekoälyn kykyjen komplementaarisuuteen ja siihen liittyvään tekoälyn tuottavuusvaikutukseen (ks. myös Mäkelä ja Stephany 2025; Teutloff ja muut 2025).
- Kolmanneksi mitä enemmän tietyllä taidolla on potentiaalisesti sitä täydentäviä taitoja, sitä enemmän vaihtoehtoja on uudelleen kouluttautumiseen. Tämä lisää sopeutumiskykyä muutoksiin, joita tekoälyn kehitys aiheuttaa jatkossa (Stephany ja Teutloff 2024).

Tarkkoja ennusteita siitä, millaisilla taidoilla työelämässä menestyy tulevaisuudessa, ei ole tämänkään tarkastelun pohjalta helppoa antaa. Hyvin yleisellä tasolla voidaan todeta, että todennäköisesti hyvin pärjäävät ne, joilla on monipuolista osaamista ja toisiaan täydentäviä taitoja – eli osaamiskokonaisuuksia, jotka ovat joko sellaisia, että tekoälyn kyvyt täydentävät niitä ja/tai jotka auttavat sopeutumaan uusiin tekoälyn kehityksen tuomiin muutoksiin (OECD 2021 ja Stephany ja Teutloff 2024).

4.2. Kodifioitavissa vs. ei-kodifioitaessa olevan tiedon merkitys

Kuten Kuviossa 2 havainnollistetaan, tekoälyä keskeisesti määrittävä ominaisuus on sen kyky suoriutua kognitiivisia kykyä edellyttävistä tehtävistä, joiden tekemisessä tarvitaan ja hyödynnetään ”ei-kodifioitavissa” tai ei-ohjelmoitavissa olevaa tietoa (Ide ja Talamas 2025).¹² Tämä erottaa tekoälypohjaiset ratkaisut esimerkiksi yritys-ohjelmistoista, kuten erilaisista toimintojen ohjaus- ja taloushallinto-ohjelmistoista, joilla voidaan automatisoida ihmisiltä kognitiivisia kykyjä edellyttäviä mutta ohjelmoitavissa tai ”kodifioitavissa” olevia tehtäviä. Tekoälyä hyödyntävät robotit eroavat puolestaan (perinteisistä) roboteista, joilla voidaan automatisoida kodifioitavissa olevia manuaalisia työtehtäviä. Ei-kodifioitavissa oleva tieto on tietyllä tavalla implisiittistä tai vaikeasti ilmaistavaa tietoa. Kodifioitavissa oleva tieto on sen sijaan eksplisiittistä ainakin siinä merkityk-

sessä, että sitä voidaan tallentaa, prosessoida ja jakaa suhteellisen helposti tietokoneohjelmistojen kannalta riittävän jäsentyneellä tavalla.

Keskeinen ero kodifioitavissa ja ei-kodifioitavissa olevan tiedon välillä on niiden siirrettävyys (Ide ja Talamas 2025). Esimerkkejä kodifioitavassa olevasta tiedosta ovat tietokantoihin tai käsikirjoihin tallennettu informaatio; tämänkaltaisen tieto on siirrettävissä, koska se voidaan ilmaista sääntöinä ja menettelytapoina. Ei-kodifioitavissa olevan tiedon siirrettävyys on sen sijaan rajallista, koska sitä ei voida ilmaista joukkona sääntöjä tai kirjoittaa muotoon, jota voidaan käsitellä tietokoneen tai tietokoneohjelman avulla.

Esimerkiksi hiljainen tieto on ei-kodifioitavissa olevaa tietoa, kun se on esimerkiksi opittu huomaamatta, kun se on implisiittistä, tai kun sitä on hankalaa pukea sanoiksi tai ilmaista luonnollisella kielellä. Ei-kodifioitavan tiedon rajallinen siirrettävyys ja jakaminen tarkoittaa, että ne ihmiset, joilla on tällaista tietoa, ovat usein pullonkauloja ko. tiedon soveltamisessa.

Kuvio 2: Tekoälyn erityispiirteet (mukaillen Ide ja Talamas 2025)

	Kodifioitavissa oleva tieto	Ei-kodifioitavissa oleva tieto
Manuaaliset tehtävät	Perinteiset robotit	Tekoäly-robotit
Kognitiivisia kykyjä edellyttävät tehtävät	Yritysohjelmistot	Tekoäly

¹² Kodifioiminen viittaa siihen, että asia voidaan ilmaista joukkona sääntöjä tai kirjoittaa tietokoneohjelman muotoon.

Ide ja Talamas (2025) arvioivat tekoälyn merkitystä analysoimalla, miten se vaikuttaa työntekijöiden ja työtehtävien organisoitumiseen tietoperusteisesti ns. osaamishierarkioiksi ja erilaisten työntekijöiden kykyyn ratkoa ongelmia (Garicano 2000). Yksi heidän keskeinen havaintonsa on, että nykyaikaiset tekoälyjärjestelmät hämärtävät rajaa kodifioitavissa ja ei-kodifioitavissa olevan tiedon välillä (Ide ja Talamas 2025), sillä ne pystyvät tunnistamaan, omaksumaan ja hyödyntämään esimerkiksi opetusaineistossa ”piilossa” (”rivien välissä”) olevaa hiljaista tietoa suorittaakseen kognitiivisia, ei-kodifioitavissa olevia tehtäviä. Kun tekoälymalli on koulutettu, se voi soveltaa aineistosta oppimiaan asioita laajassa mittakaavassa, jolloin se ikään kuin kodifioi hiljaisen tiedon omiksi parametreikseen. Tämän ansiosta tieto on siirrettävissä tietokoneille, vaikka se ei olisikaan siirrettävissä suoraviivaisesti tai nopeasti ihmisille. Tekoälyn ansiosta tietyn ei-kodifioitavissa olevan tiedon hyödyntäminen ei ole enää riippuvainen yksittäisen asiantuntijan ajasta, sillä sitä voidaan hyödyntää moniin eri tarkoituksiin samanaikaisesti, kun se on kodifioitu tekoälymalliin (Ide ja Talamas 2025).

Ide ja Talamas (2025) nostavat esiin myös, että monien tekoälysovellusten taustalla olevien perustamallien voidaan tulkita olevan monikäyttöisiä tekoälyalustoja, joita voidaan hyödyntää monissa erilaisissa tehtävissä vain vähäisellä ”lisäkoulutuksella”. Tämän yleiskäyttöisyyden ansiosta esimerkiksi yritykset ja organisaatiot voivat hyödyntää pientä määrää yhteiskäytössä olevia tekoälymalleja. Tällöin muutama iso yleiskäyttöinen kielimalli on hyvin laajassa käytössä eikä tarvetta yritysten omien ja toimialakohtaisten tekoälyjärjestelmien kehittämiseksi synny. Tämä osaltaan tekee mahdolliseksi sen, että niitä käytetään laajasti – periaatteessa kai-

killä yrityksillä on käytettävissään samankaltainen, edistynyt ja hiljaisen (aiemmin ei-kodifioitavissa olevan) tiedon hyödyntämisen mahdollistava tekoälyratkaisu.

Ide ja Talamas (2025) esittävät, että tekoälyn vaikutuksissa on selkeitä eroja riippuen siitä, arvioidaanko ongelmanratkaisussa avustavien tekoälyapulaisien (*co-pilots*) merkitystä, vai tarkastellaanko ns. tekoälytyökavereita (*co-workers*), jotka suorittavat tuotantotehtäviä itsenäisesti. Heidän mallitarkastelunsa ennustaa, että autonomiset tekoälytyökaverit hyödyttävät erityisesti kyvykkäitä ja osaavia ihmisiä, kun taas ei-autonomiset tekoälyapulaiset hyödyttävät erityisesti vähemmän kyvykkäitä ja osaavia yksilöitä. Tämä jälkimmäinen vaikutus syntyy, koska ei-autonomiset tekoälyapulaiset auttavat vähemmän kyvykkäitä ratkaisemaan ongelmia, joita he eivät aiemmin kyenneet ratkaisemaan.

Näiden havaintojen lisäksi voidaan kysyä, johtaako tekoälyn kehitys siihen, että kouluista ja yliopistoista valmistuvia palkataan vähemmän, jos tekoäly kykenee osin tekemään tehtäviä, joita vastavalmistuneet ovat tyypillisesti tehneet. Mikäli näin käy, missä ja miten nämä vastavalmistuneet pätevöityvät ja saavat relevanttia työkokemusta, jota kokeneemmilla asiantuntijoilla tyypillisesti on?

5. Lopuksi

Kuten on käynyt monien uusien teknologioiden kohdalla aiemminkin, myös tekoälyn kehityksestä ja merkityksestä tehdyissä arvioissa on ollut nähtävissä tietynasteista ylioptimismia siitä, miten tekoäly kehittyy ja kuinka nopeasti se tapahtuu. Tätä kirjoittaessa näkemykset siitä, että puhtaasti neuroverkkopohjaiset tekoälymallit voisivat parantua yhtä nopeasti kuin viime ai-

koina ja johtaa jonkinlaiseen yleistekoölyyn (*artificial general intelligence*) ovat synkentyneet.

Yksi syy näkemysten synkentymiseen on ollut melko laajasti jaettu pettymys OpenAI:n uuden GPT-5-tekoölymallin suorituskykyyn. Malli on parannus suhteessa aiempaan, mutta ei vaikuta vastaavan odotuksiin, joita siihen oli ladattu. Tämä kertonee mm. siitä, että vaikka määrällinen skaalaus opetusvaiheessa on aiemmin johtanut merkittäviin laadullisiin muutoksiin tekoölymallien suorituskyvyissä, skaalauksesta saatavat suorituskyvyn parannukset ovat pienentyneet. Toinen syy näkemysten synkentymiseen ovat uudet ja alati kasvavat havainnot siitä, että suuret kieli- ja päättelymallit (LLM- ja LRM- mallit) eivät kykene käsittelemään ongelmia ja tuottamaan ratkaisuja, joita varten pitäisi onnistua yleistämään opetusaineiston jakauman ulkopuolelle (Zhao ja muut 2025). Ketjupäättelyäkään hyödyntävät LRM-mallit eivät vaikuta pystyvän yleistettävään päättelyyn ja ongelman ratkaisuun. Kuten mm. Marcus ja muut (1999) ja Marcus (2022) ovat jo pidempään esittäneet, tämä ei ole sattumaa vaan periaatteellinen ongelma puhtaasti aineisto-opetukseen perustavassa neuroverkkomallinnuksessa.

Tämä LLM- ja LRM- mallien puute liittyy keskeisesti siihen, että näille malleille ei (todennäköisesti) ole opetuksen myötä syntynyt ns. sisäistä maailmamallia (*world model*), eli tekoölymallin sisäistä abstraktia esitystä ympäristöstään, liittyen esimerkiksi relevantteihin syyseuraussuhteisiin, toimijoiden ja asioiden väliin vuorovaikutussuhteisiin tai fysiikan lakeihin (ks. Marcus ja Davis 2019, Del Ser ja muut 2025). Maailmamallit ovat tietynlaisia kognitiivisia kehikkoja, joiden avulla järjestelmä (kone, ihminen tai eläin) voi seurata ja arvioida, mitä maailmassa tapahtuu (Marcus ja Davis 2019). Tällaisen sisäisen laskennallisen, ympäröivää

maailmaa kuvaavan viitekehyksen avulla tekoöly voisi sisäisesti simuloida ja ennakoida, miten sen toimet vaikuttavat maailmaan ja suunnitella tulevia toimia ilman jatkuvaa kokeilua ja erehdystä, kun se on vuorovaikutuksessa oikean maailman, kuten keskustelussa tekoölyn käyttäjien kanssa. Jos tällaisia maailmamalleja ei ole käytettävissä, tekoölyllä ei ole tarvittavaa kontekstietoisuutta ja kykyä tiivistää ja yhdistää erilaisia esimerkkejä abstrakteiksi representatioiksi (kuvauksiksi) ympäröivästä maailmasta (Shani ja muut 2025). Se ei siksi kykene ennustamaan maailman tilaa (*state of world*) syötteessä kenties kerrottua pidemmälle, kuten esimerkiksi kysymykselle relevantin ympäristön tilaa tai ongelman ratkaisuun tarvittavien välivaiheiden muuttujien arvoja, ja siten arvioimaan (”simuloimaan”) päättelynsä tai toimiensa merkitystä pidemmälle tai niiden seurauksia.¹³

Huolimatta edellä sanotusta on varmaa, että ihmisten ja tekoölyn välinen yhteistyö tulee olemaan jatkossa yhä yleisempää ja että jonkinlaista tekoölyä hyödynnetään jatkossa mitä erilaisimmissa työtehtävissä. Erityisesti alati kehittyvät tekoölyagentit tulevat muuttamaan työn luonnetta tavalla, jota on vaikeaa arvioida.

Tästä seuraa, että kyky käyttää tekoölyä taroituksenmukaisesti, tehokkaasti ja eettisesti korostuu tulevaisuudessa (Euroopan parlamentti, 2025). Vaikka ns. tekoölyn lukutaitoa (*AI-literacy*) on hankalaa määritellä, on melko selvää, että se ei tarkoita vain toimivien syötteiden laatimista ja hyödyntämistä tai yleisemmin suurten kielimallien sujuvaa käyttöä. Te-

¹³ Yhdeksi ratkaisuksi tähän ongelmaan on ehdotettu ns. *neuro-symbolisia hybridimalleja*, jotka pyrkivät yhdistämään *neuroverkkojen* kyvyn oppia laajoista aineistoista säännönmukaisuuksia symbolisten järjestelmien loogiseen päättelyyn (Marcus 2019, Marcus 2020).

koälyn lukutaitoon voidaan lukea ainakin seuraavat: i) teknologiset ja kvantitatiiviset taidot eli riittävä tekninen ymmärrys tekoälystä ja sen soveltamisesta; ii) osaaminen liittyen ihmisen ja tekoälyn vuorovaikutukseen ja tekoälyagenttien hallintaan eli kyky työskennellä tehokkaasti tekoälyn ja tekoälyagenttien kanssa mm. delegoimalla niille tehtäviä, ohjaamalla niitä oikeaan suuntaan pitkissä ja epäselvemmissä päättelyti-

lanteissa ja ratkaisemalla ongelmia niiden avulla; iii) kriittinen ajattelu ja eettinen ymmärrys eli taito ymmärtää tekoälyjärjestelmien toimintaa, tunnistaa niiden tuotoksissa olevia puutteita ja vinoumia ja pohtia eettisiä kysymyksiä. Myös jatkuva oppiminen ja uudelleen kouluttautuminen ovat välttämättömiä tekoälyn nopean kehityksen vuoksi. □

Kirjallisuus

- Acemoglu, D. (2025). "The simple macroeconomics of AI", *Economic Policy* 40: 13–58.
- Acemoglu, D., Kong, F., ja Restrepo, P. (2025), "Tasks at work: comparative advantage, technology and labor demand", NBER työpäperi 32872 (päivitetty).
- Acemoglu, D., ja Autor, D. (2011), "Skills, tasks and technologies: Implications for employment and earnings", teoksessa D. Card ja O. Ashenfelter (toim.), *Handbook of Labor Economics* (Vol. 4B), Elsevier: 1043–1171.
- Aghion, P., Jones, B. F., ja Jones, C. I. (2019), "Artificial intelligence and economic growth", teoksessa A. Agrawal, A. J. Gans, J. ja Goldfarb, A. (toim.), *The Economics of Artificial Intelligence: An agenda*, University of Chicago Press: 237–282.
- Alekseeva, L., Azar, J., Giné, M., ja Samila, S. (2024), "AI adoption and the demand for managerial expertise", FEB Research Report MSI_2412.
- Amodei, D. (2024): *Machines of Loving Grace: How AI Could Transform the World for the Better*, <https://darioamodei.com/machines-of-loving-grace> (viitattu 22.8.2025).
- Antràs, P., Garicano, L., ja Rossi-Hansberg, E. (2006), "Offshoring in a knowledge economy", *Quarterly Journal of Economics* 121(1): 31–77.
- Arthur, W. B. (2009), *The nature of technology: What it is and how it evolves*. Free Press.
- Autor, D. H. (2013), "The 'task approach' to labor markets: An overview", *Journal for Labour Market Research*, 46(3): 185–199.
- Berger, P. G., W. Cai, L. Qiu, ja C. Xinyi Shen (2024), "Employer and employee responses to generative ai: Early evidence", SSRN työpäperi 4874061.
- Bender, E. M., Gebru, T., McMillan-Major, A. ja Shmitchell, S. (2021), "On the dangers of stochastic parrots: Can language models be too big?" *Proceedings of the 2021 ACM conference on fairness, accountability, and transparency*: 610–623.
- Berti, L., Giorgi, F., ja Kasneci, G. (2025), "Emergent abilities in large language models: A survey", arXiv:2503.05788.
- Caplin, A., D. J. Deming, S. Li, D. J. Martin, P. Marx, B. Weidmann, and K. J. Ye (2024), "The abc's of who benefits from working with ai: Ability, beliefs, and calibration", NBER työpäperi 33021.
- Chan, A., Wei, K., Huang, S., Rajkumar, N., Perrier, E., Lazar, S., ... ja Anderljung, M. (2025), "Infrastructure for ai agents", arXiv preprint arXiv:2501.10114.
- Chang, H.-F., ja Li, T. (2025), "A framework for collaborating with a large language model tool in

- brainstorming for triggering creative thoughts“, *Thinking Skills and Creativity* 56: 101755.
- Cockburn, I. M., Henderson, R., ja Stern, S. (2018), “The impact of artificial intelligence on innovation: An exploratory analysis, teoksessa A. Agrawal, A. J. Gans, J. ja Goldfarb, A. (toim.), *The Economics of Artificial Intelligence: An agenda*, The economics of artificial intelligence: An agenda. University of Chicago Press: 115–146
- Cohen, M. K., Kolt, N. Bengio, Y. Hadfield, G. K. ja Russell, S. (2024), “Regulating advanced artificial agents”, *Science* 384(6691): 36–38.
- Davidson, T. (2021), “Could advanced AI drive explosive economic growth”, *Open Philanthropy* 25.
- Del Ser, J., Lobo, J. L., Müller, H., ja Holzinger, A. (2025), “World models in artificial intelligence: Sensing, learning, and reasoning like a child”, arXiv preprint arXiv:2503.15168.
- Douglas, M. R., ja Verstyuk, S. (2025), “Progress in artificial intelligence and its determinants”, arXiv preprint arXiv:2501.17894.
- Erdil, E., ja Besiroglu, T. (2023), “Explosive growth from AI automation: A review of the arguments“, arXiv preprint arXiv:2309.11690.
- European Parliament (2025), *What role for AI skills in (re-)shaping the future European workforce?*, Policy Department Study. Brussels.
- Fuchs, W., Garicano, L., ja Rayo, L. (2015), “Optimal contracting and the organization of knowledge”, *Review of Economic Studies* 82(2): 632–658.
- Ganji, G., ja Zarifhonarvar, A. (2025), “Understanding AI agents’ decision-making: Evidence from risk and time preference elicitation”, SSRN työpaperi.
- Garicano, L. (2000), “Hierarchies and the organization of knowledge in production”, *Journal of Political Economy* 108(5): 874–904.
- Garicano, L., ja Rossi-Hansberg, E. (2004), “Inequality and the organization of knowledge”, *American Economic Review* 94(2): 197–202.
- Good, I. J. (1965), “Speculations concerning the first ultraintelligent machine”, *Advances in Computers* 6: 31–88.
- Griliches, Z. (1957), “Hybrid corn: An exploration in the economics of technological change”, *Econometrica* 25(4): 501–522.
- Hosseinioun, M., Neffke, F., Zhang, L., ja Youn, H. (2025), “Skill dependencies uncover nested human capital”, *Nature Human Behaviour*: 1–15.
- Ide, E., ja Talamas, E. (2025), “Artificial intelligence in the knowledge economy”, *Journal of Political Economy*, tulossa.
- Immorlica, N., Lucier, B., ja Slivkins, A. (2024) “Generative ai as economic agents”, *ACM SIGecom Exchanges* 22(1): 93–109.
- Ishibashi, Y., Yano, T., ja Oyamada, M. (2024), “Can large language models invent algorithms to improve themselves?: Algorithm discovery for recursive self-improvement through reinforcement learning”, arXiv preprint arXiv:2410.15639.
- Jones, C. I. (2024), “The ai dilemma: Growth versus existential risk”, *American Economic Review: Insights* 6(4): 575–590.
- Kambhampati, S. (2024), “Can large language models reason and plan?”, *Annals of the New York Academy of Sciences* 1534(1): 15–18.
- Kambhampati, S., Stechly, S., ja Valmeekam, R. (2025), “(How) Do reasoning models reason?“, *Annals of the New York Academy of Sciences* 1547(1): 33–40.
- Kauhanen, A., Pajarinen, M. ja Rouvinen, P. (2023), “Occupational exposure to text- and code-generating artificial intelligence in Finland”, ETLA Brief no. 127 (25.10.2023).
- Kauhanen, A., Kässä, O., Pajarinen, M., Rouvinen, P. ja Vanhala, P. (2024), ”Generatiivisen tekoälyn käyttö Suomessa: Havainnot syksyn 2024 kyselystä”, ETLA Muistio nro 144 (19.11.2024).
- Kauhanen, A., ja Rouvinen, P. (2025), “Assessing early labour market effects of generative AI: evidence from population data”, *Applied Economics Letters* 1–4.

- Krishnan, N. (2025), "Ai agents: Evolution, architecture, and real-world applications", arXiv preprint arXiv:2503.12687.
- Korinek, A. (2023), "Generative AI for economic research: Use cases and implications for economists", *Journal of Economic Literature* 61(4): 1281–1317.
- Korinek, A. (2024), "LLMs level up—Better, faster, cheaper: June 2024 update to section 3 of "Generative AI for economic research: Use cases and implications for economists", *Journal of Economic Literature* 61(4): 1–38.
- Korinek, A. (2025), "AI Agents for Economic Research: Mid-2025 Update to 'Generative AI for Economic Research: Use Cases and Implications for Economists,' published in the *Journal of Economic Literature* 61(4)
- Kuusi, T. (2025). "GenAI, Growth, and the Multi-Sector Multipliers", ETLA Working Papers No 131 (14.8.2025).
- Marcus, G. F., Vijayan, S., Bandi Rao, S., ja Vishton, P. M. (1999), "Rule learning by seven-month-old infants", *Science* 283(5398): 77–80.
- Marcus, G., ja Davis, E. (2019), "Rebooting AI: Building artificial intelligence we can trust", Vintage.
- Marcus, G. (2020), "The next decade in AI: Four steps towards robust artificial Intelligence", arXiv:2002.06177.
- Marcus, G. (2022), "Deep learning is hitting a wall", *Nautilus* 10.
- McCoy, R. T., Yao, S., Friedman, D., Hardy, M. D., ja Griffiths, T. L. (2024), "Embers of autoregression show how large language models are shaped by the problem they are trained to solve", *Proceedings of National Academy of Sciences* 121(41).
- Mäkelä, E., ja Stephany, F. (2025), "Complement or substitute? How AI increases the demand for human skills", arXiv preprint arXiv:2412.19754.
- Nie, S., Zhu, F., You, Z., Zhang, X., Ou, J., Hu, J., ... ja Li, C. (2025), "Large language diffusion models", arXiv preprint arXiv:2502.09992.
- Nordhaus, W. D. (2021), "Are we approaching an economic singularity? Information technology and the future of economic growth", *American Economic Journal: Macroeconomics* 13(1): 299–332.
- OECD. (2021), *AI and the future of skills, volume 1: Capabilities and assessments*, OECD Publishing.
- Peltonen, J. ja Silvo, A. (2025), "Tekoäly kiihdyttää kasvua, jos talous sopeutuu rakennemuutokseen", EurojaTalous 11.8.2025 (Eurojatalous.fi).
- Raman, N. K., Lundy, T., Amouyal, S. J., Levine, Y., Leyton-Brown, K., ja Tennenholtz, M. (2024), "Rationality report cards: Assessing the economic rationality of large language models", arXiv:2402.09552.
- Shafayat, S., Tajwar, F., Salakhutdinov, R., Schneider, J., ja Zquette, A. (2025), "Can large reasoning models self-train?", arXiv preprint arXiv:2505.21444.
- Shani, C., Jurafsky, D., LeCun, Y., ja Shwartz-Ziv, R. (2025), "From tokens to thoughts: How LLMs and humans trade compression for meaning", arXiv preprint arXiv:2505.17117.
- Shojaee, P., Mirzadeh, I., Alizadeh, K., Horton, M., Bengio, S., ja Farajtabar, M. (2025), "The illusion of thinking: Understanding the strengths and limitations of reasoning models via the lens of problem complexity", arXiv preprint arXiv:2506.06941.
- Stephany, F., ja Teutloff, O. (2024), "What is the price of a skill? The value of complementarity", *Research Policy* 53(1): 104898.
- Teutloff, O., Einsiedler, J., Kässi, O., Braesemann, F., Mishkin, P., ja del Rio-Chanona, R. M. (2025), "Winners and losers of generative AI: Early Evidence of Shifts in Freelancer Demand", *Journal of Economic Behavior ja Organization* 235: 106845.
- Trammell, P., ja Korinek, A. (2023), "Economic growth under transformative AI", NBER työpaperi 31815.
- Turing, A. M. (1950), "Computing machinery and intelligence", *Mind* 59(236): 433–460.

- Vaswani, A., Shazeer, N., Parmar, N., Uszkoreit, J., Jones, L., Gomez, A. N., ... ja Polosukhin, I. (2017), "Attention is all you need", *Advances in neural information processing systems* 30.
- Vinge, V. (1993), "The coming technological singularity: How to survive in the post-human era", *Vision-21: Interdisciplinary science and engineering in the era of cyberspace*, NASA Conference Publication 10129.
- Wang, L., Ma, C., Feng, X., Zhang, Z., Yang, H., Zhang, J., ... ja Wen, J. (2024), "A survey on large language model based autonomous agents", *Frontiers of Computer Science* 18(6): 186345.
- Wei, J., Wang, X., Schuurmans, D., Bosma, M., Xia, F., Chi, E., ... ja Zhou, D. (2022), "Chain-of-thought prompting elicits reasoning in large language models", *Advances in neural information processing systems* 35: 24824–24837.
- Weitzman, M. L. (1998), "Recombinant growth", *Quarterly Journal of Economics* 113(2): 331–360.
- Yang, L., Zhang, Z., Song, Y., Hong, S., Xu, R., Zhao, Y., ... ja Yang, M. H. (2023), "Diffusion models: A comprehensive survey of methods and applications", *ACM computing surveys* 56(4): 1–39.
- Zhao, C., Tan, Z., Ma, P., Li, D., Jiang, B., Wang, Y., ... ja Liu, H. (2025), "Is chain-of-thought reasoning of LLMs a mirage? A Data Distribution Lens", arXiv preprint arXiv:2508.01191.*