

Santeri Mikkonen

Yksilön valinta evoluutioalgoritmeissa

Tietotekniikan kandidaatintutkielma

27. toukokuuta 2022

Jyväskylän yliopisto

Informaatioteknologian tiedekunta

Tekijä: Santeri Mikkonen

Yhteystiedot: santeri.m.mikkonen@student.jyu.fi

Ohjaaja: Tytti Saksa

Työn nimi: Yksilön valinta evoluutioalgoritmeissa

Title in English: Selection of individual in evolutionary algorithms

Työ: Kandidaatintutkielma

Opintosuunta: Tietotekniikka

Sivumäärä: 21+0

Tiivistelmä: Yksilön valintaprosessi on merkittävä osa evoluutioalgoritmien toimintaa. Tässä tutkielmassa tarkastellaan yksilön eri evaluointi- ja valintatapoja niiden suorituskyvyn ja käyttökohteiden näkökulmasta katsottuna. Tutkielman tavoitteena on myös vertailla eri evaluointi- ja valintatapoja keskenään.

Avainsanat: evoluutioalgoritmi, sopivuusfunktio, uutuushaku, yllätyshaku, vähimmäiskriteeri, turnausvalinta, rulettivalinta, elitismivalinta

Abstract: Individual selection process is an important part of the operation of evolutionary algorithms. This thesis examines different individual's evaluation and selection methods from the point of view of their performance and applications. The motive of thesis is also to compare different evaluation and selection methods with each other.

Keywords: evolutionary algorithm, fitness function, novelty search, surprise search, minimal criteria, tournament selection, roulette selection, elitism selection

Kuviot

Kuvio 1. Suhteellinen rulettivalinta.....	10
Kuvio 2. Sijoitusperusteinen rulettivalinta	11

Sisällys

1	JOHDANTO	1
2	EVOLUUTIOALGORITMIT	2
3	EVALUOINTI	4
3.1	Sopivuusfunktio	4
3.2	Tavoiteperusteinen haku	4
3.3	Uutuushaku	5
3.4	Yllätysshaku	6
3.5	Suorituskyky ja evaluointitapojen yhdistäminen.....	7
4	VALINTATAVAT	8
4.1	Turnausvalinta	8
4.2	Rulettivalinta	10
4.2.1	Suhteellinen rulettivalinta	10
4.2.2	Sijoitusperusteinen rulettivalinta	10
4.3	Elitismivalinta	11
4.4	Valintatapojen suorituskyky	12
5	YHTEENVETO.....	13
	LÄHTEET	14

1 Johdanto

Luonnon evoluutio on aikojen saatossa tuottanut uskomattoman kompleksisia toiminnallisuuksia ja tuloksia, joista merkittävimpänä esimerkkinä on ihmisen evoluutio. Tulokset ovat inspiroineet tutkijoita abstrahoimaan evoluutiota ja selvittämään mitkä eri tekijät ovat mahdollistaneet tämän korkean tason kompleksisuuden saavuttamisen (Lehman ja Stanley 2010). Tältä pohjalta syntyivät evoluutiolaskenta ja sen osajoukko, evoluutioalgoritmit, 1900-luvun puolivälissä (De Jong, Fogel ja Schwefel 1997).

Tämä tutkielma tutkii evoluutioalgoritmeissa yksilön valintaan käytettäviä evoluutiotaapoja ja niiden suorituskykyä, sekä peilaa valintatapoja luonnon evoluutioprosessiin. Evoluutioalgoritmit eivät sovellu hyvin kompleksisten tehtävien suorittamiseen, mutta valintatapojen optimoinnilla pystytään suorittamaan entistä kompleksisempia tehtäviä. Tutkielma käy läpi kolme evoluutioalgoritmien yksilön evaluointitapaa ja kolme valintatapaa. Tutkielman tavoitteena on täten kartoittaa evoluutioalgoritmien yksilön valintaprosessia, tutkia eri evaluointi- ja valintatapojen ominaisuuksia ja arvioida saatujen tulosten perusteella evaluointi- ja valintatapoja keskenään muun muassa niiden suorituskyvyn näkökulmasta katsottuna.

2 Evoluutioalgoritmit

Vikhar (2016) määrittelee evoluutioalgoritmien olevan Darwinin evoluutioteorian inspiroimia heuristisia hakumenetelmiä, jotka käyttävät hyväkseen simuloitua evoluutiota löytääkseen ratkaisuja optimointiongelmiin. Evoluutioalgoritmien toiminta perustuu luonnon evoluution neljään mekanismiin: valintaan, risteytykseen, mutaatioon ja lisääntymiseen. Seuraava kappale pohjautuu kirjoittajien Razali ja Geraghty (2011) ja Power, Sweeney ja Cowan (1999) tutkimusartikkeleihin ja kuvaa evoluutioalgoritmien toiminnan Algoritmin 1 pseudokoodin mukaisesti.

Evoluutioalgoritmin (Algoritmi 1) ensimmäisessä vaiheessa populaatio luodaan käyttäen satunnaisia arvoja. Populaation jokainen yksilö kuvastaa yhtä ratkaisua ongelmaan. Seuraavaksi populaation yksilöt evaluoidaan käytetyn evalointitavan mukaisesti, jonka jälkeen populaatiosta valitaan halutut yksilöt kahden tai useamman yksilön pareihin populaation manipulointiprosessia varten. Manipulointiprosessi alkaa populaation yksilöparien risteytyksellä. Risteytyksessä yksilöiden geenitiedot yhdistyvät niin, että molempien edeltävän yksilön geenitiedot sekoittuvat keskenään. Viimeisessä vaiheessa yksilöiden geenitiedot mutatoidaan. Manipulointiprosessin suoritettua uusi sukupolvi on syntynyt ja sen yksilöt evaluoidaan. Jos evaluoinnin jälkeen ennalta asetetut kriteerit täyttyvät tai populaation yksilöt ovat lähentyneet optimaaliseen ratkaisuun, algoritmin suoritus pysäytetään ja populaatiosta valitaan paras yksilö, muuten algoritmin suoritusta jatketaan.

Evoluutiolaskennan osajoukolle tyypillisesti evoluutioalgoritmit ovat tehokkaita kompleksisissa optimointiongelmissa hyvän häiriönsietokykyisyyden ja joustavuuden ansiosta (Vikhar 2016). Muita evoluutioalgoritmeille tyypillisiä hyötyjä ovat muun muassa yksinkertaisuus, laaja sovellettavuus, tehokkuus globaaleissa optimointiongelmissa – kuten NP-täydellisissä ongelmissa – ja kyvykyys rinnakkais-suoritukseen (Du ym. 2018).

Algoritmi 1 Evoluutioalgoritmi

1: **Aloita**

2: Luo populaatio satunnaisilla arvoilla

3: Evaluoi populaation yksilöt

4: **Toista**

5: Valitse populaatiosta yksilöparit risteytystä varten

6: Risteytä yksilöt

7: Mutatoi risteytetyt yksilöt

8: Evaluoi uuden populaation yksilöt

9: **Kunnes** jokin kriteeri saavutetaan

10: **Lopeta**

3 Evaluointi

Evoluutioalgoritmeissa evaluointi on yksi merkittävimmistä vaiheista algoritmin suorituskyvyn näkökulmasta katsottuna. Evaluoinnin tarkoituksena on asettaa jokaiselle populaation yksilölle arvo, joka kuvaa kuinka hyvin yksilö vastaa käyttäjän määrittämiin sopivuusfunktion mittareihin. Tässä tutkielmassa mittarit jaetaan kolmeen osaan: tavoiteperusteiseen hakuun, uutuushakuun ja yllätyshakuun. Lisäksi sopivuusfunktio ja tavoiteperusteinen haku on eritelty omiksi alaluvuiksi ja tämän takia sopivuusfunktiota tarkastellaan tutkielmassa toiminnallisesta näkökulmasta katsottuna. Tässä luvussa käydään läpi sopivuusfunktion toimintaperiaate, edellä luetellut kolme sopivuusfunktion mittaria sekä tutkitaan niiden suorituskykyä ja evaluointitapojen yhdistämistä.

3.1 Sopivuusfunktio

Sopivuusfunktio ilmaisee yksilön kyvyn ratkaista tietty ongelma (Aslam 2015). Sopivuusfunktio ottaa syötteenä evaluoitavan yksilön ja palauttaa yksilön sopivuuden ongelman ratkaisemiseen käytetyn kriteerin mukaisesti. Aslam (2015) korostaa oikean sopivuusfunktion valitsemisen merkitystä ja sopivuusfunktion roolia evoluutioprosessin ohjaajana. Yleisen määrittelyn mukaan sopivuusfunktioiden vaikeus määräytyy niiden aikavaativuuksien perusteella (He, Chen ja Yao 2015). Kun aikavaativuus on polynomiaikainen, on kyse helposta sopivuusfunktioista. Vaikean sopivuusfunktion käsitettä käytetään taas silloin, kun aikavaativuus on eksponentiaalinen (He, Chen ja Yao 2015). Sopivuusfunktioiden ongelmia ovat muun muassa hidas suoritus aika ja kohtuuttomat kustannukset. Joskus ongelmana voi olla, ettei ongelman ratkaisuun ole olemassa sopivuusfunktiota (Davarynejad, Akbarzadeh-T ja Pariz 2007)

3.2 Tavoiteperusteinen haku

Tavoiteperusteisessa haussa sopivuusfunktion toiminta määräytyy käyttäjän asettamien tavoitteiden mukaisesti. Yksilöt, jotka saavuttavat asetetut tavoitteet parhaiten, evaluoidaan muita laadukkaammiksi. Lehman ja Stanley (2011) kertovat, että taustalla on näkemys siitä,

että paras tapa kehittää suorituskykyä on palkita tavoitteeseen suhteessa tapahtuvaa suorituskyvyn paranemista. Tavoiteperusteisesta hausta ongelmallisen tekee tavoitteiden laatiminen. Jos tavoitteena on päästä mahdollisimman lähelle optimaalista ratkaisua, esimerkiksi sokkelotestissä, on riskinä palkita yksilöitä jotka pääsevät lähelle tavoitetta, mutta ajautuvat umpikujaan, josta yksilön on mahdoton saavuttaa tavoite (Huang, Nitschke ja Shorten 2015). Lehman ja Stanley (2011) toteavatkin, että saman käyttäytymisen voi rinnastaa muihinkin harhauttaviin ongelmiin. Kehittääkseen harhauttaviin ongelmiin eri lähestystavan, tutkijat ovat laajentaneet yhden tavoitteen ongelmia monitavoitteisiksi ongelmiksi harhautuksen välttämiseksi (Lehman ja Stanley 2011). Monitavoitteiset ongelmat eivät täysin poista harhautuksen vaikutusta, mutta Razali ja Geraghty (2011) ovat todistaneet ongelmien monitavoitteistamisen vähentäneen paikalliseen optimiin vaikutusta.

3.3 Uutuushaku

Lehman ja Stanley (2010) määrittelevät uutuushaun pääidean olevan uusien käyttäytymismallien palkitsemisen keinona saavuttaa edistysaskelia kohti ongelman ratkaisua. Tämä eroaa tavoiteperusteisesta hausta siinä, että lopullisen tavoitteen sijaan uutuushaku keskittyy etsimään aiemmista toiminnallisuuksista tai käyttäytymisestä poikkeavia yksilöitä (Gravina, Liapis ja Yannakakis 2017). Lehmanin ja Stanleyyn (2010) mukaan tämän ansiosta uutuushaku pystyy välttämään ajautumasta paikalliseen optimiin.

Uutuushaulla on samoja piirteitä luonnon evoluution kanssa. Lehman ja Stanley (2010) mainitsevat yhdeksi piirteeksi lopullisen tavoitteen puuttumisen. Luonnon evoluutio ei noudata mitään lopullisia tavoitteita, vaan pelkästään toimii noudattaen vähimmäiskriteerejä selviytymisen ja lisääntymisen näkökulmasta. Vaikka luonnollisen evoluution vähimmäiskriteereitä on aina oltava lisääntyminen ja selviytyminen, uutuushaussa ei ole kyseistä rajoitusta. Uutuushaussa pystytään valitsemaan mitkä tahansa kriteerit vähimmäiskriteereiksi, jotka vastaavat sidonnaisesti tosielämän ongelmia. Lehman ja Stanley (2010) laskevat toiseksi piirteeksi taipumuksen kartuttaa uusia eliöiden muotoja.

Uutuushaussa yksilöiden uutuus mitataan selvittämällä niiden välinen käytöksellinen tai geeniperäinen etäisyys aiempiin yksilöihin verrattuna. Tätä varten aiemmista yksilöistä ja niiden

tutkimista käyttäytymisen alueista pidetään arkistoa (Shorten ja Nitschke 2014). Jos populaatio mallinnettaisiin käytöksellisten etäisyyksiensä kautta, uutuushaku suosisi harvaan sijoittautuneita yksilöitä yksilörykelmien sijaan (Lehman ja Stanley 2010).

Gravina, Liapis ja Yannakakis (2017) viittaavat tutkimusartikkelissaan uutuushaun luontaisien ominaisuuksien, uutuuden, palkitsemisen olevan keino päästä eroon harhautuksesta. Harhautus on Gravinan, Liapisin ja Yannakakisin (2017) mukaan suuri haaste evoluutiolaskennassa ja sitä käytetään ongelmien vaikeustason mittaamisessa. Uutuushaku soveltuu adaptiivisiin käyttökohteisiin parhaiten ja auttavat etenkin ratkaisemaan harhautusta keinotekoisien neuroverkkojen kehittämisessä (Risi ym. 2009).

Shorten ja Nitschke (2014) mainitsevat uutuushaun olevan kritisoitu vastaavan käytännössä pelkkää satunnaishakua. He myös havaitsivat sokkelotestissään uutuushaun olevan heikompi kehittymään tavoiteperusteiseen hakuun verrattuna.

3.4 Yllätysshaku

Yllätysshaun idea perustuu kognitiivisen tieteen esitykseen, että yllätys on keskeinen sisäinen tekijä luovuudelle ja sen lopputuloksille (Grace ja Maher 2015; Gravina, Liapis ja Yannakakis 2016). Yllätysshaussa palkitaan odotetusta käyttäytymisestä poikkeavia ratkaisuja ennaltanäkemättömien tai uusien ratkaisujen sijaan. Uutuushakuun verrattuna yllätysshaussa ei laajenneta hakualuetta, vaan jo aiemmin tutkitusta hakualueesta etsitään ratkaisuja, tehden yllätysshausta tehokkaamman hakutavan hakukentän tutkimisessa uutuushakuun nähden (Grace ja Maher 2015). Kuten uutuushaussa, populaation yksilöistä ja niiden käyttäytymisestä pidetään arkistoa (Gravina, Liapis ja Yannakakis 2016).

Odotetun käyttäytymisen määrittämiseksi tulee määrittää ratkaistavasta ongelmasta riippuen lähestymistavat kolmeen kysymykseen: miten ratkaisuarkiston yksilöitä painotetaan nykyisen sukupolven yksilöiden nähden, mitä ennustavaa mallia käytetään ja kuinka paikallisia tai globaaleja käyttäytymiä tarkastellaan (Gravina, Liapis ja Yannakakis 2016). Kun odotettu käyttäytyminen on määritetty, voidaan laskea arvio yksilön käyttäytymisen poikkeavuudesta. Gravina, Liapis ja Yannakakis (2016) määrittävät yllätysarvon s populaation yksilölle i laskemiseksi kaavan 3.4, jossa d_s on yksilön ja sen odotetun käyttäytymisen välisen eron

mitta, $p_{i,j}$ on j :n lähin ennustepiste yksilöön i nähden ja n on tarkasteltujen ennustepisteiden lukumäärä.

$$s(i) = \frac{1}{n} \sum_{j=0}^n d_s(i, p_{i,j})$$

3.5 Suorituskyky ja evaluointitapojen yhdistäminen

Evaluointitapojen suorituskykyä on verrattu keskenään useissa eri tutkimuksissa. Harhauttavissa testeissä, kuten sokkelotesteissä, uutuus- ja yllätys-haku ovat olleet tavoiteperusteiseen hakuun verrattuna selkeästi tehokkaampia ongelman ratkaisemisessa (Gravina, Liapis ja Yannakakis 2016; Risi ym. 2009). Kyseisissä testeissä uutuus- ja yllätys-haku suoriutuvat lähes yhtä tehokkaasti toisiinsa nähden, mutta yllätys-haku onnistui löytämään ratkaisun keskimäärin nopeammin uutuushakuun verrattuna.

Evaluointitapoja on myös yhdistetty ja tutkimuksissa on saatu lupaavia tuloksia. Gravina, Liapis ja Yannakakis (2017) ovat todistaneet sokkelotestissä uutuus- ja yllätys-haun välisen yhdistelmän toimivan tehokkaammin, kuin osatekijänsä. Tutkimuksen tulokset osoittavat yhdistämisen olevan hyödyllinen myös kestävyuden ja käyttäytymisen monimuotoisuuden näkökulmasta katsottuna. Lehman, Stanley ja Miikkulainen (2013) ovat tutkineet myös evaluointitapojen yhdistämistä. He huomasivat tutkimuksessaan tavoiteperusteisen haun ja uutuushaun yhdistelmän suoriutuvan keskimäärin paremmin osatekijöihinsä ja niiden muihin yhdistelmiin verrattuna sokkelo- ja kaksijalkaisessa liikkumistestissä ongelman vaikeudesta huolimatta.

4 Valintatavat

Yksilöiden evaluoinnin jälkeen yksilöt valitaan populaatiosta käyttäen haluttua valintatapaa manipulointiprosessia varten. Evoluutioalgoritmeissa valintatapa määrittää mitkä yksilöt valitaan tuottamaan seuraavan sukupolven jälkeläiset ja määrä kuinka monta jälkeläistä kukin yksilö tuottaa (Razali ja Geraghty 2011). Valintatapojen tavoitteena on parantaa populaation keskimääräistä laatua mahdollistaen laadukkaampien yksilöiden, ja etenkin niiden hyvien ominaisuuksien, siirtymisen seuraavaan sukupolveen evoluutioprosessissa (Blickle ja Thiele 1996), (Sokolov ja Whitley 2005). Vaikka laadukkaampien yksilöiden valitseminen on merkittävässä roolissa, Blickle ja Thiele (1996) ja Razali ja Geraghty (2011) molemmat korostavat etsinnän ja hyödyntämisen välistä tasapainoa. Tämä tarkoittaa sitä, että laadukkaampien yksilöiden pitää tulla valituksi suuremmalla todennäköisyydellä kuin huonojen yksilöiden, mutta samaan aikaan huonoilla yksilöillä pitää olla myös mahdollisuus tulla valituksi seuraavaan sukupolveen.

Razali ja Geraghty (2011) kuvaavat valintatapojen toimivan populaation manipulointiprosessiin verrattuna päin vastaisesti hakualueen suhteen; valintatavat kaventavat halutun ratkaisun hakualueita, kun taas mutaatio ja geneettinen siirtymä (manipulointiprosessi) avartavat sitä.

Tässä luvussa käydään läpi kolme keskeisintä evoluutioalgoritmien yksilön valintatapaa ja tarkastellaan niiden suorituskykyä, ominaisuuksia ja käyttökohteita tarkemmin. Luvun lopussa valintatapoja verrataan keskenään ja tuloksista vedetään tarvittavat johtopäätökset.

4.1 Turnausvalinta

Turnausvalinta on suosittu valintatapa, jossa populaatiosta valitaan tietty määrä yksilöitä satunnaisesti ja nämä yksilöt muodostavat turnauksen, jossa yksilöt kamppailevat toisiaan vastaan (Blickle ja Thiele 1996). Razalin ja Geraghtyn (2011) mukaan turnausvalinta koostuu yksittäisistä turnauksista, joihin osallistuu yleisimmin kaksi yksilöä. Turnaukseen osallistuvien yksilöiden määrä määrittää turnauksen koon. Kahden yksilön turnauksesta käytetään käsitettä *binääriturnaus* (Blickle ja Thiele 1996). Turnausvalinnassa yksilöiden evaluointiarvo suhteessa populaatioon määrittää valitsemistodennäköisyyden. Turnauksen evaluoin-

tiarvoltaan paras yksilö voittaa turnauksen ja jatkaa luomaan uuden populaation (Blickle ja Thiele 1996). Uusi populaatio aloittaa saman prosessin kunnes N sukupolven päästä lopetuskriteeri on saavutettu. Kriteereitä voi olla muun muassa haluttuun ratkaisuun päätyminen, suoritusajaka- tai kustannusrajan ylittyminen tai ratkaisujen laadun muuttumattomuus sukupolvien määrän kasvaessa.

Razali ja Geraghty (2011) nimeävät turnausvalinnan vahvuuksiksi sen tehokkuuden ja yksinkertaisuuden. Turnausvalinta vaatii muihin valintatapoihin verrattuna pienemmän määrän iteraatioita halutun ratkaisun löytämiseksi. Tämä näkyy suoritusajoissa ja parhaimmillaan turnausvalinnan aikavaativuus on $O(n)$, jos yksilöt valitaan deterministisesti (Blickle ja Thiele 1996). Turvausvalinta mahdollistaa rinnakkaissuorituksen ja jokainen turnaus pystytään suorittamaan samaan aikaan, jos prosessorien määrä on sama kuin populaation koko (Sokolov ja Whitley 2005). Orriols-Puig ym. (2007) mainitsevat myös turnausvalinnan vahvuudeksi sen häiriönsietokykyisyyden. Häiriönsietokyvyllä kuvataan kykenevyyttä suoriutua tehtävästä ongelmitta odottamattomista olosuhteista riippumatta.


Turnausvalinnalla on myös heikkoutensa. Sokolov ja Whitley (2005) huomauttavat, että yksilöiden monimuotoisuus heikkenee merkittävästi populaation koon kasvaessa. Mitä suurempi populaatio on kyseessä, sitä pienempi osajoukko populaatiosta vaikuttaa seuraavan sukupolven monimuotoisuuteen. Razali ja Geraghty (2011) tukevat tätä ja nimeävät kaksi mahdollista tekijää monimuotoisuuden heikkenemiseen: hyvät yksilöt eivät saata tulla valituksi turnaukseen tai hävittyään yksilöt eivät tule valituksi seuraavaan sukupolveen. Monimuotoisuuden heikentyessä riskinä on paikallisiin optimeihin päätyminen. Paikalliset optimit voivat olla naapuriratkaisuihin verrattuna hyviä ratkaisuja ongelmaan, mutta eivät ongelman ratkaisun kannalta hyviä tai tehokkaita. Populaation ollessa suuri, turnausvalinnalla on myös vaikeuksia päästä optimaaliseen ratkaisuun. Razalin ja Geraghtyn (2011) laskennallisessa koeksessa kauppatkustajan ongelman optimoinnissa, turnausvalinnan ratkaisun poikkeamatiedetystä optimaalisesta ratkaisusta oli suurimmillaan 10.33 prosenttia laajemmissa ongelmissa, kun taas pienemmissä ongelmissa turnausvalinta pääsi optimaaliseen ratkaisuun.

4.2 Rulettivalinta

Rulettivalinta laskee kullekin yksilölle sen evaluointiarvon vastaavan osuuden koko väestön evaluointiarvoon verrattuna. Tämän jälkeen populaatiosta valitaan yksilö evaluointiarvon määräämän todennäköisyyden perusteella luomaan uusi populaatio (Zhang, Chang ja Xu 2012). Rulettivalinta voidaan jakaa kahteen eri tyyppiin yksilön valinnan todennäköisyyden määrittämistavan perusteella: suhteelliseen rulettivalintaan ja arvoperusteiseen rulettivalintaan.

4.2.1 Suhteellinen rulettivalinta

Suhteellisessa rulettivalinnassa yksilöt valitaan niiden todennäköisyyksien perusteella, jotka ovat verrannollisia niiden sopivuusarvoon suhteutettuna koko populaation sopivuusarvojen summaan (Shukla, Pandey ja Mehrotra 2015). Koko populaatioon suhteutettuna korkeamman sopivuusarvon omaavien yksilöiden valintatodennäköisyys on suurempi kuin yksilöillä, joilla on muuhun populaatioon suhteutettuna alhaisemmat sopivuusarvot (Razali ja Geraghty 2011). Rulettipyörän segmenttien koot vastaavat siis populaation eri yksilöiden valintatodennäköisyyksiä.



Kuvio 1. Kuva suhteellisesta rulettivalinnasta

4.2.2 Sijoitusperusteinen rulettivalinta

Sijoitusperusteinen rulettivalinta pohjautuu yksilöiden sopivuusarvojen mukaiseen keskinäiseen järjestykseen koko populaation välillä (Razali ja Geraghty 2011). Sijoitusperusteinen

rulettivalinnan alussa yksilöt lajitellaan sopivuusarvojensa mukaisesti koko populaation kesken järjestykseen, jonka jälkeen jokaiselle yksilölle lasketaan valintatodennäköisyys sijoituksensa perusteella. Voidaan ottaa käyttöön valintapaineparametri, jolla kerrotaan yksilöiden sijoitukset. Valintapaine parametrin arvoavaruus määrittää onko kyse lineaarisesta vai epälineaarista sijoitusvalinnasta. Lineaarisesta sijoitusvalinnasta on kyse silloin, kun valintapaineparametri voi saada arvoja 1.0 ja 2.0 välillä (Razali ja Geraghty 2011), kun taas epälineaarinen sijoitusvalinta sallii 2.0 suurempien valintapainearvojen käytön. Lineaarisessa sijoitusvalinnassa valintatodennäköisyys on verrannollinen yksilön sijoitukseen, kun taas epälineaarissa sijoitusvalinnassa valintatodennäköisyydet perustuvat kunkin yksilön sijoitukseen, mutta eivät ole verrannollisia sijoitukseen nähden.

$s=100$

35 1.	30 2.	20 3.	15 4.
----------	----------	----------	----------

Kuvio 2. Kuva sijoitusperusteisesta rulettivalinnasta

4.3 Elitismivalinta

Du ym. (2018) määrittävät elitismivalinnan keinoina käyttää hyödyntämistä apuna valitsemalla populaatiosta vain fitnessarvoltaan parhaimmat yksilöt. Ahn ja Ramakrishna (2003) ja Du ym. (2018) nostavat molemmat esiin, miten tämä prosessi vähentää geneettistä taipumusta. Elitismivalinnan vahvuutena muihin valintatapoihin verrattuna on haluttuun ratkaisuun parempi lähentymisnopeus (Du ym. 2018), mutta saman aikaisesti tämä asettaa sen riskialttiiksi populaation monimuotoisuuden heikkenemiselle ja voi estää päätyminen globaaliin optimiin. Helppo implementointi ja toteutus on myös eräs elitismivalinnan hyvistä puolista.

4.4 Valintatapojen suorituskyky

Yksilön valintatapojen suorituskykyä on tutkittu laajasti useissa eri tutkimuksissa. Zhongin ym. (2005) tekemässä tutkimuksessa turnausvalinta suoriutui rulettivalintaa paremmin testifunktioiden maksimien ja minimien ratkaisemisessa käyttäen yksinkertaista geneettistä algoritmia. Tulokset osoittivat myös turnausvalinnan konvergoivan nopeammin turnausvalintaan verrattuna. Blickle ja Thiele (1996) huomasivat tutkimuksessaan sijoitusperusteisen rulettivalinnan käyttäytyvän ja suoriutuvan samalla lailla binääriturnaukseen verrattuna populaation koon ollessa pieni.

Razalin ja Geraghtyn (2011) tutkimuksessa kauppamatkustajan ongelman ratkaisemisessa sijoitusperusteinen rulettivalinta suoriutui paremmin tiedettyyn optimiin pääsemisessä suhteelliseen rulettivalintaan ja turnausvalintaan verrattuna. Tutkimuksen tulokset osoittavat kuitenkin sijoitusperusteisen rulettivalinnan suorituskyvyllä olevan hintansa: sijoitusperusteinen rulettivalinta konvergoituu muita valintatapoja hitaammin ja sen iteraatioiden suoritus aika on kaikista hitain. Razali ja Geraghty (2011) toteavatkin turnausvalinnan soveltuvan parhaiten kooltaan pienten ongelmien ratkaisemiseen, kun taas he mainitsevat sijoitusperusteisen rulettivalinnan olevan paras vaihtoehto suurten ongelmien ratkaisemiseen, etenkin jos ratkaisun laatu on pääprioriteetti ongelman ratkaisemisessa ja laskenta-ajan suhteen pystytään joustaa.

5 Yhteenveto

Tutkielma keskittyi selvittämään evoluutioalgoritmien yksilön eri valinta- ja evaluointitapoja ja niiden ominaisuuksia ja suorituskykyä verrattuna toisiinsa. Tutkielman tuloksista kävi ilmi, että evoluutioalgoritmien toteutuksessa on lähestytty kohti luonnon evoluutiota ja siirrytty tavoiteperusteisista tavoista, monipuolisuutta ja hakukentän avartaviin tapoihin ja saavutettu aiempaa parempia tuloksia. Tutkielma havainnoi myös tarpeen jatkotutkimuksille evaluointi- ja valintatapojen yhdistämisestä sekä elitismivalinnasta tutkimusten määrän vähäisyyden takia. Tulevaisuuden suunta evoluutioalgoritmien evaluointi- ja valintaprosesseissa näyttää olevan kohti hybridimalleja ja uusien tapojen kehittämistä kohti. Nähtäväksi jää, kuinka lähelle luonnon evoluution toiminallisuutta evoluutioalgoritmeissa päästään tulevaisuudessa.

Lähteet

- Ahn, Chang Wook, ja R.S. Ramakrishna. 2003. “Elitism-based compact genetic algorithms”. *IEEE Transactions on Evolutionary Computation* 7 (4): 367–385. <https://doi.org/10.1109/TEVC.2003.814633>.
- Aslam, Muhammad Waqar. 2015. “Selection of fitness function in genetic programming for binary classification”. Teoksessa *2015 Science and Information Conference (SAI)*, 489–493. <https://doi.org/10.1109/SAI.2015.7237187>.
- Blickle, Tobias, ja Lothar Thiele. 1996. “A Comparison of Selection Schemes Used in Evolutionary Algorithms”. *Evolutionary Computation* 4, numero 4 (joulu): 361–394. ISSN: 1063-6560. <https://doi.org/10.1162/evco.1996.4.4.361>. eprint: <https://direct.mit.edu/evco/article-pdf/4/4/361/1492921/evco.1996.4.4.361.pdf>.
- Davarynejad, M., M.-R. Akbarzadeh-T ja N. Pariz. 2007. “A novel general framework for evolutionary optimization: Adaptive fuzzy fitness granulation”. Teoksessa *2007 IEEE Congress on Evolutionary Computation*, 951–956. <https://doi.org/10.1109/CEC.2007.4424572>.
- De Jong, Kenneth, David Fogel ja Hans-Paul Schwefel. 1997. “A history of evolutionary computation”, A2.3:1–12. Tammikuu.
- Du, Haiming, Zaichao Wang, Wei Zhan ja Jinyi Guo. 2018. “Elitism and Distance Strategy for Selection of Evolutionary Algorithms”. *IEEE Access* 6:44531–44541. <https://doi.org/10.1109/ACCESS.2018.2861760>.
- Grace, Kazjon, ja Mary Lou Maher. 2015. “Specific curiosity as a cause and consequence of transformational creativity.” Teoksessa *ICCC*, 260–267.
- Gravina, Daniele, Antonios Liapis ja Georgios Yannakakis. 2016. “Surprise Search: Beyond Objectives and Novelty”. Teoksessa *Proceedings of the Genetic and Evolutionary Computation Conference 2016*, 677–684. GECCO '16. Denver, Colorado, USA: Association for Computing Machinery. ISBN: 9781450342063. <https://doi.org/10.1145/2908812.2908817>. <https://doi.org/10.1145/2908812.2908817>.

Gravina, Daniele, Antonios Liapis ja Georgios Yannakakis. 2017. “Coupling Novelty and Surprise for Evolutionary Divergence”. Teoksessa *Proceedings of the Genetic and Evolutionary Computation Conference*, 107–114. GECCO '17. Berlin, Germany: Association for Computing Machinery. ISBN: 9781450349208. <https://doi.org/10.1145/3071178.3071179>. <https://doi.org/10.1145/3071178.3071179>.

He, Jun, Tianshi Chen ja Xin Yao. 2015. “On the Easiest and Hardest Fitness Functions”. *IEEE Transactions on Evolutionary Computation* 19 (2): 295–305. <https://doi.org/10.1109/TEVC.2014.2318025>.

Huang, Chien-Lun Allen, Geoff Nitschke ja David Shorten. 2015. “Searching for novelty in pole balancing”. Teoksessa *2015 IEEE Congress on Evolutionary Computation (CEC)*, 1792–1798. <https://doi.org/10.1109/CEC.2015.7257104>.

Lehman, Joel, ja Kenneth Stanley. 2010. “Revising the Evolutionary Computation Abstraction: Minimal Criteria Novelty Search”. Teoksessa *Proceedings of the 12th Annual Conference on Genetic and Evolutionary Computation*, 103–110. GECCO '10. Portland, Oregon, USA: Association for Computing Machinery. ISBN: 9781450300728. <https://doi.org/10.1145/1830483.1830503>. <https://doi.org/10.1145/1830483.1830503>.

———. 2011. “Abandoning Objectives: Evolution Through the Search for Novelty Alone”. *Evolutionary computation* 19 (kesäkuu): 189–223. https://doi.org/10.1162/EVCO_a_00025.

Lehman, Joel, Kenneth O. Stanley ja Risto Miikkulainen. 2013. “Effective Diversity Maintenance in Deceptive Domains”. Teoksessa *Proceedings of the 15th Annual Conference on Genetic and Evolutionary Computation*, 215–222. GECCO '13. Amsterdam, The Netherlands: Association for Computing Machinery. ISBN: 9781450319638. <https://doi.org/10.1145/2463372.2463393>. <https://doi.org/10.1145/2463372.2463393>.

Orriols-Puig, Albert, Kumara Sastry, Pier Luca Lanzi, David E. Goldberg ja Ester Bernadó-Mansilla. 2007. “Modeling Selection Pressure in XCS for Proportionate and Tournament Selection”. Teoksessa *Proceedings of the 9th Annual Conference on Genetic and Evolutionary Computation*, 1846–1853. GECCO '07. London, England: Association for Computing Machinery. ISBN: 9781595936974. <https://doi.org/10.1145/1276958.1277325>. <https://doi.org/10.1145/1276958.1277325>.

- Power, P., F. Sweeney ja C.F.N. Cowan. 1999. "EA crossover schemes for a MLP channel equaliser". Teoksessa *ICECS'99. Proceedings of ICECS '99. 6th IEEE International Conference on Electronics, Circuits and Systems (Cat. No.99EX357)*, nide 1, 407–410 vol.1. <https://doi.org/10.1109/ICECS.1999.812309>.
- Razali, Noraini, ja John Geraghty. 2011. "Genetic Algorithm Performance with Different Selection Strategies in Solving TSP", nide 2. Tammikuu.
- Risi, Sebastian, Sandy D. Vanderbleek, Charles E. Hughes ja Kenneth O. Stanley. 2009. "How Novelty Search Escapes the Deceptive Trap of Learning to Learn". Teoksessa *Proceedings of the 11th Annual Conference on Genetic and Evolutionary Computation*, 153–160. GECCO '09. Montreal, Québec, Canada: Association for Computing Machinery. ISBN: 9781605583259. <https://doi.org/10.1145/1569901.1569923>. <https://doi.org/10.1145/1569901.1569923>.
- Shorten, David, ja Geoff Nitschke. 2014. "How evolvable is novelty search?" Teoksessa *2014 IEEE International Conference on Evolvable Systems*, 125–132. <https://doi.org/10.1109/ICES.2014.7008731>.
- Shukla, Anupriya, Hari Mohan Pandey ja Deepti Mehrotra. 2015. "Comparative review of selection techniques in genetic algorithm". Teoksessa *2015 International Conference on Futuristic Trends on Computational Analysis and Knowledge Management (ABLAZE)*, 515–519. <https://doi.org/10.1109/ABLAZE.2015.7154916>.
- Sokolov, Artem, ja Darrell Whitley. 2005. "Unbiased Tournament Selection". Teoksessa *Proceedings of the 7th Annual Conference on Genetic and Evolutionary Computation*, 1131–1138. GECCO '05. Washington DC, USA: Association for Computing Machinery. ISBN: 1595930108. <https://doi.org/10.1145/1068009.1068198>. <https://doi.org/10.1145/1068009.1068198>.
- Vikhar, Pradnya A. 2016. "Evolutionary algorithms: A critical review and its future prospects". Teoksessa *2016 International Conference on Global Trends in Signal Processing, Information Computing and Communication (ICGTSPICC)*, 261–265. <https://doi.org/10.1109/ICGTSPICC.2016.7955308>.

Zhang, Liming, Huiyou Chang ja Ruitian Xu. 2012. “Equal-Width Partitioning Roulette Wheel Selection in Genetic Algorithm”. Teoksessa *2012 Conference on Technologies and Applications of Artificial Intelligence*, 62–67. <https://doi.org/10.1109/TAAI.2012.21>.

Zhong, Jinghui, Xiaomin Hu, Jun Zhang ja Min Gu. 2005. “Comparison of Performance between Different Selection Strategies on Simple Genetic Algorithms”. Teoksessa *International Conference on Computational Intelligence for Modelling, Control and Automation and International Conference on Intelligent Agents, Web Technologies and Internet Commerce (CIMCA-IAWTIC'06)*, 2:1115–1121. <https://doi.org/10.1109/CIMCA.2005.1631619>.