

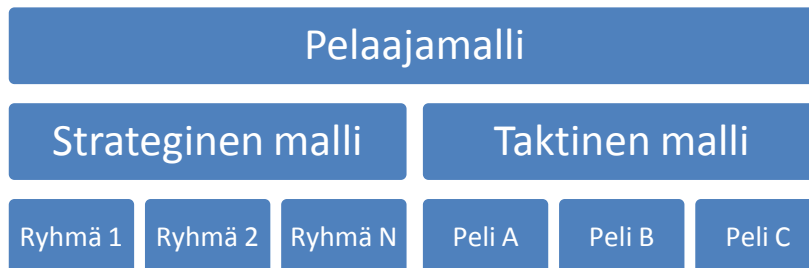
Yleinen kuvaus mallintamisen tavoitteista

Projektin tarkoituksena on mallintaa ja analysoida rahapelejä säännöllisesti pelaavien toimintaa. Tutkimusmenetelmänä käytetään tilastollista datan analysointia ja sen pohjalta luotujen mallien rakenteen suunnittelua ja tulkitsemista. Kiinnostus mallien rakentamiseen on lähtöisin uusien pelien kehityksen ja testaamisen tarpeista. Tuotekehityksen tavoitteena on luoda vetovoimaisia peli-ideoita, joiden säännöt ja positiivinen palaute ennakoivat pelin kiinnostavuutta. Uuden pelin kiinnostavuuden yksi tärkeimmistä mittareista kertakäyttöpelien maailmassa on aikavälin pituus, jonka jälkeen pelaamiskerrat jäävät hyvin satunnaisiksi. Harvasta pelistä tulee kesto suosikki, joiden ennustaminen lienee mahdotonta.

Perinteisesti peli-ideoita on tutkittu keräämällä laajan testipelaaja joukon reaktioita kyselyillä. Näiden järjestäminen on työlästä ja kallista. Testaaminen on silti kannattavaa, koska halutaan välttää mm. imago tappioita ”tylsän” pelin lanseeraamisesta ja välttää resurssien käyttö pelin viimeistelyyn, joka sääntöjensä puolesta ei vetoa mitenkään yleisöön. Rahapelien näkökulmasta on hyvä selvittää myös erilaisten pelaajatyypin taktiikoiden vaikutus palautusprosenttiin. Lisäksi olisi mielenkiintoista tutkia vastuullisuus näkökulmasta, miten toistuvaa ja intensiivistä pelaaminen on pitkällä aikavälillä. Tämänkaltaisten asioiden selvittämisen helpottamiseksi olisi mielenkiintoista rakentaa saatavilla olevan datan perusteella malli, ja soveltaa sen ennustetta uuteen peli-ideaan.

Pelaamisen mallintamisen yksi suurista haasteista on pyrkiä ennustamaan käyttäytymistä harvinaisesta pelaamisesta kertyvän puutteellisen datan perusteella. Pätevän mallin pohjana täytyy olla aktiivisen pelaamisen pohjalta kerätty data, joka ei välttämättä vastaa todellisten, eli harvoin pelaavien ja tavoittamattomien pelaajaryhmien käyttäytymistä. Malli saattaa pohjautua epäaidosti vakio pelaajan rutiininomaiseen käyttäytymiseen.

Pelaamista kuvaava malli voidaan jaotella osamalliksi erilaisista peliryhmistä (hedelmäpelit, arpapelit, urheilupelit) ja pelaajaryhmistä (nuoret, keski-ikäiset, tms) kerätyn aineiston perusteella. Luotavien mallien analysointi voidaan jakaa tarkastelu-aikavälin perusteella yksittäisten pelikertojen mallintamiseen ja pitkän aikavälin pelisessoiden välisen kausi käyttäytymisen tarkasteluun. Tätä jaottelua on mahdollisesti tarpeellista jatkaa kohti yhä pelikohtaisempaa mallinnusta. Tarkoituksena on kuitenkin luoda mahdollisen yleispätevä malli, jotta sovellusalue olisi laaja.



Hahmottelemamme menetelmä jakaa mallinnuksen alustavasti kahteen pääosaan: strateginen ja taktinen malli. Pelaajien pitkänaikavälin käyttäytymistä ja eri pelikertojen vuorovaikutusta kuvataan strategisella mallilla. Se pitää sisällään kuvauksen, jolla aiemmista peleistä tullut palaute (voitot, häviöt, raha, kesto) ja valittu pelityyli (varma, varovainen, aggressiivinen) suhteutetaan seuraavaan pelikertaan. Näitä mallinnettavia asioita ovat esimerkiksi erilaiset todennäköisyydet tehdä tietyn tyyppinen taktinen valinta seuraavan pelin aikana. Näiden valintojen yksityiskohdat ja parametrisointi on hyvin pelikohtaista ja sen vuoksi ne määritellään erikseen nk. taktisella mallilla. Lisäksi strategiseen malliin kuuluu pelikertojen välisten taukojen pituus, johon oletettavasti vaikuttaa nykyisen pelaamisputken pelikerrat ja pelimenestys. Tämä osuus mallintamisesta on tarkoitus automatisoida hyvin pitkälle, kun on päätetty miten taktiselle mallille syötetään parametrit ja miten aiempien pelikertojen tieto formalisoidaan.

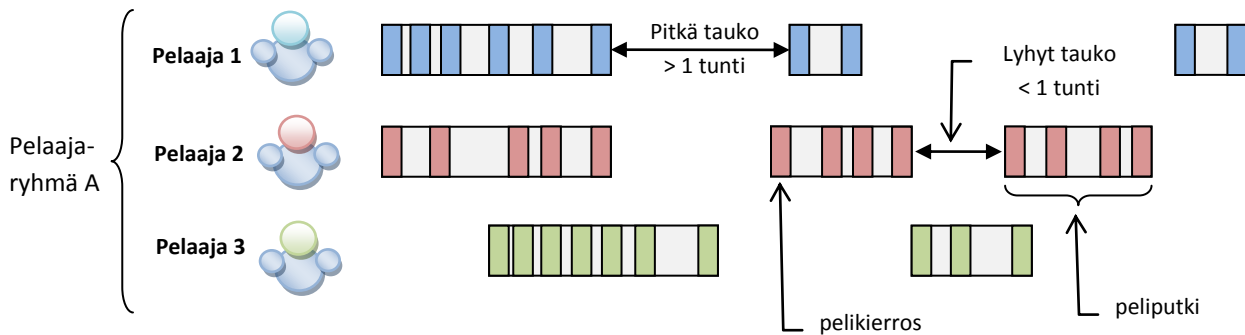


Figure 1 Käsittekaavio

Seuraavan pelin käyttäytymisen ennustetaan riippuvan kokonaisuutena hyvin paljon aluksi määritettävästä strategia-mallin tilasta. Tila vaihtelee sessioiden välillä, ja tähän vaikuttaa myös pelihistoria sekä tunnetut pelaajan henkilökohtaiset ominaisuudet. Tämä tila määrittelee eräänlaisen pelikerran tavoitetta kuvaavan parametrijoukon (strategiset vakiot) ja sen avulla lyödään lukkoon pelikerran aikana tehtävien päätösten tilastollisen jakauman parametrit. Näiden lähtöparametrien pelikohtainen merkitys on tämän tutkimuksen kohdealueella uutta ja tuntematonta tapauskohtaista tietoa, toisin sanoen pelaajakäyttäytymisen taktista mallia ei ole ja sitä ei voida louhia mistään. Tämän vuoksi uuden pelin kehittäjän pelikohtaisen näkemyksen mukaan luodaan taktinen malli, joka kuvaa mitä strategian edellyttämä siirto merkitsee konkreettisesti pelin eri tilanteissa. Mallin viimeinen vaihe, joka kuvaa strategiset todennäköisyydet päätöksiksi, on siis käytännössä peliasiantuntijan luoma algoritmikuvaus.

Tämä mallin jaottelu mahdollistaa pelin mallintamisen esimerkiksi tietynlaisilla simuloituilla käyttäjäryhmillä, jos halutaan selvittää palautusprosentti, keskimääräisen pelisession pituus, yms vaikkapa tietyllä ryhmällä. Strateginen malli voidaan muodostaa erilaisista käyttäjäryhmistä kerätyn datan perusteella, jolloin simulaation lisätään vain haluttujen ryhmien edustajia sopivassa suhteessa. Pelaajaryhmien tunnistamiseen kehitetty tärkeä työkalu on ohjaamattomaan oppimiseen pystyvä SOM (Itseorganisoituva kartta), jolla voidaan visuaalisesti rajata 2-ulotteiselta ruudukolta merkittäviä käyttäjätyhentyä(klusteri). Rajaamalla ryhmät voidaan varmistaa, että luodaan erikseen jokaista

merkittävää ja todellista ryhmää kuvaava strateginen malli. Ryhmän sisäiset vaihtelut pelaajakäyttäytymisessä ovat todennäköisesti hallittuja, joten niiden pohjalta on helpompi luoda malli matemaattisessa mielessä. Samalla vältytään tavoittelemasta yleispätevää ja keskiarvoistavaa mallia, joka mallintaa jokaisen ryhmän keskimääräisen huonosti. Hajoita ja hallitse!

Menetelmät osana ratkaisua

Yleistä

Yksi lähtökohta pelien mallintamisessa on tuottaa ohessa myös helpottajuinen malli, jonka analysointi sujuu ilman laajaa asiantuntemusta itse mallinnusmenetelmästä. Toisaalta yksinkertaisen mallin todentaminen sujuu helposti käytännön järkeilyllä. Tämä vaatimus rajoittaa useiden numeerisesti tehokkaiden menetelmien kiinnostavuutta (support vector machine, artificial neural network), jotka hukkaavat varsinkin nominaalisten (lueteltu) muuttujien merkityksen asettamalla ne yksilotteisesti lukuakselille. Nominaaliset muuttujat on toisaalta mahdollista esikäsittelyssä kuvata esimerkiksi binäärisesti, mutta se johtaa ulottuvuuksien määrän nopeaan kasvuun ja monimutkaistaa mallia.

Toiseksi varsinkin neurolaskentaan pohjautuvat menetelmät tuottavat loputtoman kompleksisen riippuvuuden, jolloin ainoa tapa tutkia mallia on asettaa testipisteitä ja tutkia ulostuloa. Tämä ei tietenkään anna selkeätä ja yleispätevää kuvaa ja tällä tavalla saadaan lähinnä kuva mallin herkkyydestä mittausvirheille ja epätavallisille syötteille. Erityisen hankalaa on yrittää soveltaa tällaista mallia ongelmaan, jossa syötteet ovat täysin uusia, koska ennuste saattaa extrapoloida ulostulon mielivaltaisesti. Esimerkiksi jos mallia luodessa ulostulot ovat aina olleet positiivisia, on mahdollista päätyä reilusti negatiiviseen ennusteeseen.

Oppivien mallien yleisiin piirteisiin kuuluu ennustaa tuntematon arvo (yleensä lähtöarvojen todennäköisin seuraus) perustuen aiemmin analysoituun aineistoon, jossa seuraus tunnetaan. Oppiminen on yleensä luonteeltaan keskiarvoistavaa, joten yksittäisten todellisten ja melko harvinaisten poikkeamien merkitys katoaa. Tämä johtuu yleisestä mallin opetustavasta, jossa mallin ulostuloa korjataan siihen suuntaan, jolla annettujen sisääntulo parametrien antama ennuste lähenee haluttua ulostuloa.

Luokitin on erityinen malli, joka ennustaa ryhmän (class label), johon annettu näyte kuuluu tunnetuista n -kpl ryhmistä. Luokittimet on oppivista menetelmistä yleisin, ja jos mallin ennusteeksi haluttaisiin numeerinen arvo, voidaan tämä arvojoukko diskretisoida. Tällöin voidaan esim. ulostulojen jakaumasta muodostaa lohkoja, jossa jokaisessa on yhtä monta näytettä. Luokitin ennustaa käytännössä vain arvovälin indeksin (eg. pieni, keskisuuri, suuri).

Mallin validointi

Projektin jatkokehittelyn kannalta olisi hyvä saada konkreettinen varmistus suunnitellun menetelmän toimivuudelle. Mallin toimivuutta voidaan luokittimen tapauksessa arvioida niin sanotun sekaannusmatriisin avulla. Se yksinkertaisesti kuvaa väärin ja oikeiden ennusteiden määrän käytetyllä opetusnäytteellä.

accuracy: 64.53% +/- 4.60% (mikro: 64.53%)			
	true range1	true range2	class precision
pred. range1	273	160	63.05%
pred. range2	117	231	66.38%
class recall	70.00%	59.08%	

Figure 2 Sekaannusmatriisi (confusion-matrix) kahden luokan tapauksessa

Idealisesti validointi pitäisi suorittaa erillisellä testi-aineistolla. Opetusvaiheessa malli luodaan minimoimalla virhe opetusnäytteillä, mutta tämä ei välttämättä johda testivirheen minimoitumiseen. Syyinä voi olla ylioppiminen, jolloin mallista tulee liian monimutkainen ja satunnaisia erikoispiirteitä noudattava. Erillisen testiaineiston saatavuus on kuitenkin yleensä heikkoa, joten käytetään nk. cross-validation menetelmää. "K-Fold" menetelmässä malli luodaan esimerkiksi 10 kertaa ja jokaisella kerralla käytetään eri 9/10 opetusnäytteistä luomiseen ja testataan mallia 1/10 näytteistä. Ennuste ja osuutarkkuudet lasketaan osatestien keskiarvoina.

Risti-validoinnin perusteella voidaan myös arvioida luotujen erillisten mallien yksituumaisuutta luokitellessa samoja näytteitä. Tätä varten on olemassa Kappa-tunnusluku (Fleiss kappa), joka ottaa huomioon yhtenevien luokitusten osuuden lisäksi sattuman mahdollisuuden. Luvulle on olemassa kiistelty kuvaileva asteikko sen arvoille 0 – 1 (slight, weak, strong agreement, jne).

Päätöspuut

Päätöspuu on mallina eksplisiittisin, ja tarjoaa tavan valita luotavan mallin monimutkaisuuden käyttäjälleen sopivaksi. Tekemällä mallista liian monimutkainen, on vaaran sortua ylioppimiseen, jolloin yksittäiset epäaidot piirteet korostuvat ja yleistettävyyttä kärsii. Päätöspuu toimii sekä numeeriselle, että nominaaliselle syöte datalle luontevasti. Tosin, jos attribuutti on reaaliluku, voi olla mielekästä jakaa sen arvoalue manuaalisesti n-kpl tasakokoisia lohkoja. Lohkojen määrän arviointi on yleensä menetelmän soveltajalle helppoa, mutta automaattiset algoritmit valitsevat haluamansa kahtia jaon.




Figure 3 Golf-pelaajan päätöksen "pelatako tänään?" mallinnus esimerkki

Päätöspuun rakentamiseen on monia tapoja, mutta tunnetuista algoritmeista ainakin ID3 ja C4.5 toimivat seuraavasti.

Lähtökohtana on aineisto, jossa ennustettavan parametrin oikea arvo tunnetaan. Ennuste näkyy puun lehtien kuvauksessa (yllä yes/no). Puuta lähdetään kasvattamaan ylhäältä rungosta tarkentamalla iteratiivisesti luokitusta aloittaen aina siitä käyttämättömästä attribuutista, jonka informaatio-arvo on suurin. Tämä päätös perustuu normalisoituun informaatio entropian erotukseen, joka saataisiin tietyllä jaottelu attribuutin valinnalla. Informaatio entropia kertoo kuinka hajanaisesti joukon näytteet kuuluvat eri kohde-ennusteiden ryhmiin. Ylemmässä esimerkkipuussa on luotu täydellinen malli, koska sen antamat luokat ovat "kiistattomia", eli ehdoilla rajoitettujen lehti-alkioiden palkit "tasavärisiä". Palkissa näkyvät värisävyt kuvaavat eri luokkien suhteellista osuutta, joista suurin on äänestetty edustamaa lehden antamaa luokka-ennustetta.

Seuraavassa on mallinnettu "Arvaa Kuka?" -pelistä kerättyjen 14-parametrin avulla siirtojen riskitason sijoittumista neljään eri luokkaan. Luokat ovat arvovälejä, jotka on valittu niin että jokaisessa on yhtä monta näytettä. Kuvasta havaitaan että korkea riskitaso on hankalin ennustettava valinta, koska punaisen värin lisäksi range4-laatikossa on muitakin värejä runsaasti. Tämä on luonnollista koska näitä näytteitä ei ole monta. Lisäksi havaitaan että informaatio-arvoltaan (ilmeisesti) merkityksettömät attribuutit puuttuvat, koska ne on puun muodostamisen loppuvaiheessa harvennettu (pruning).

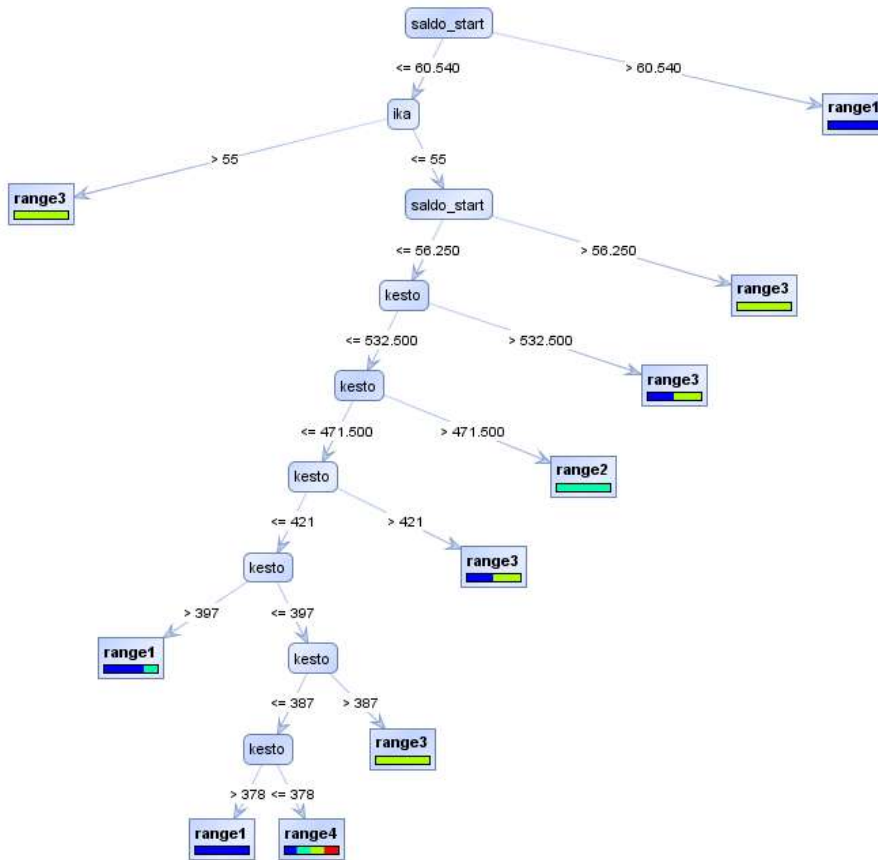


Figure 4 Pelaajan valitsema riskitaso range1 – range4 mallinnettuna pelistä Arvaa Kuka?

Päätöspuiden ideaa on kehitetty eteenpäin rakentamalla niistä ”päättömetsä”, siten että kehitetään yksittäisiä puita käyttäen vain valikoitua joukko lähtö-attribuuteista. Tällaisen luokittimen antama luokitus perustuu puiden antamien äänten enemmistöön.

Yksi päätöspuiden yhteydessä yleisesti käytetty meta-algorithmi on ”bagging = bootstrap aggregation”. Sen tarkoituksena on vähentää ylioppimisen riskiä luomalla myös useampia puita. Jokaisen puun rakentamisessa käytetään alkuperäisistä opetusnäytteistä palauttavalla näytteistyksellä kerättyä joukkoa. Tällöin suuri osa opetusnäytteistä tuplaantuu. Lopullinen luokitus määräytyy myös nyt äänestämällä.

SOM

Itseorganisoituvan kartan idean taustalla on luoda yksinkertainen visualisointi moniulotteiselle datalle. Menetelmä generoi heuristisesti esim 100x150 ruutu-alkion kartan, jossa jokainen ruutu on nk. prototyyppi-alkio tai neuroni. Prototyyppi on vektori alkuperäisessä data-avaruudessa. Tarkoituksena on iteroimalla muuntaa näiden kartta-alkioiden vektoreita siten, että ne mallintavat alkuperäisen datan topologian mahdollisimman hyvin. Oikeassa avaruudessa (esim euklidisesti) lähellä olevat pisteitä vastaa myös kartalla lähekkäiset prototyyppi-alkiot. Yleensä kartta-alkioita on kuitenkin vähemmän kuin

alkuperäistä dataa. Jotta kuvauksen vääristymät olisivat vähäisiä luodaan kartasta reunoistaan jatkuva-pinta, joka vastaa rinkiän vaippaa.




Figure 5 SOM-kartan topologia (Torus)

Luodun kartan tärkein käyttötarkoitus on tunnistaa monimutkaisia tihentymiä ja yhtenäisiä joukkoja (klustereita) moniulotteisessa datassa. Verrattuna muihin ohjaamattoman oppimisen menetelmiin kuten K-means etuna on epätavallinen kyky erotella esimerkiksi kaksi kietoutunutta rinkiämäistä joukkoa, joita ei pysty erottamaan hyper-tasomaisella pinnalla. Alla on kuvakaappaus kehitetystä klusterointi-työkalusta.

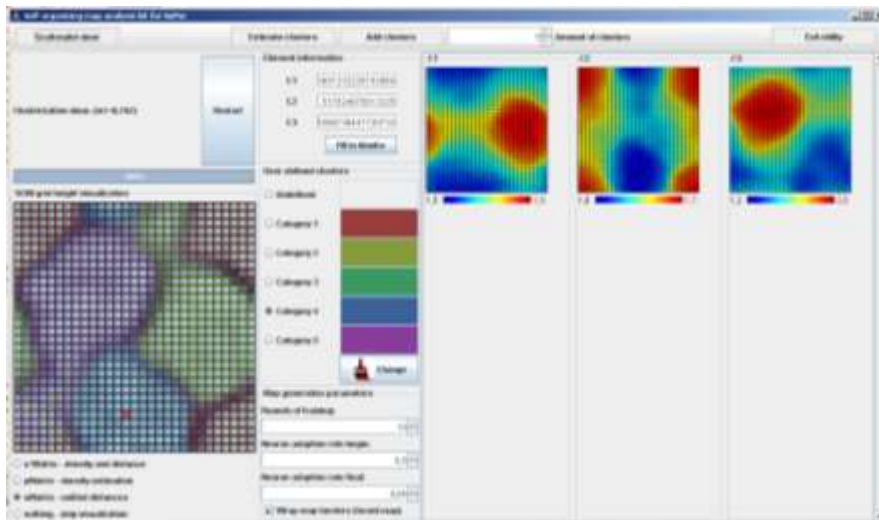


Figure 6 SOM-kartan luominen ja klusterointi käytännössä

Työkaluun on tavallisen SOM-kartan muodostamisen lisäksi rakennettu klusterointia avustavia ominaisuuksia. Vasemmalla on näkymä, jolla saadaan näkyviin yksi kolmesta tapauskohtaisesti pätevästä tihentymä kartasta. uMatrix kuvaa keskimääräisiä prototyyppi-alkioiden etäisyyksiä ja pMatrix näiden estimoitua tiheyttä ja u*Matrix pyrkii keskiarvoistamaan kummankin menetelmän parhaat puolet. Oikealla puolella on näkyvissä vastaavien prototyyppi-alkioiden yksittäisten komponenttien kartat asteikkoineen. Tarkat numeroarvot saa selville valitsemalla alkion hiirellä. Keskipaneelissa on väritystyökalu, jolla tihentymäkartasta voidaan manuaalisesti muodostaa joukkoja. Lähtökohtana voidaan käyttää perinteisen K-means menetelmän alustavasti luomaa jakoa (Estimate clusters). Aluksi on kuitenkin oltava tuntuma siitä montaa ryhmää halutaan muodostaa (Amount of clusters). SOM-kartan muodostamista varten on valittavissa muutamia parametrejä, joiden valitsemiseen ei ole olemassa mitään sääntöjä. Tärkeintä on päätyä karttaan, josta erottuu selkeitä joukkoja.

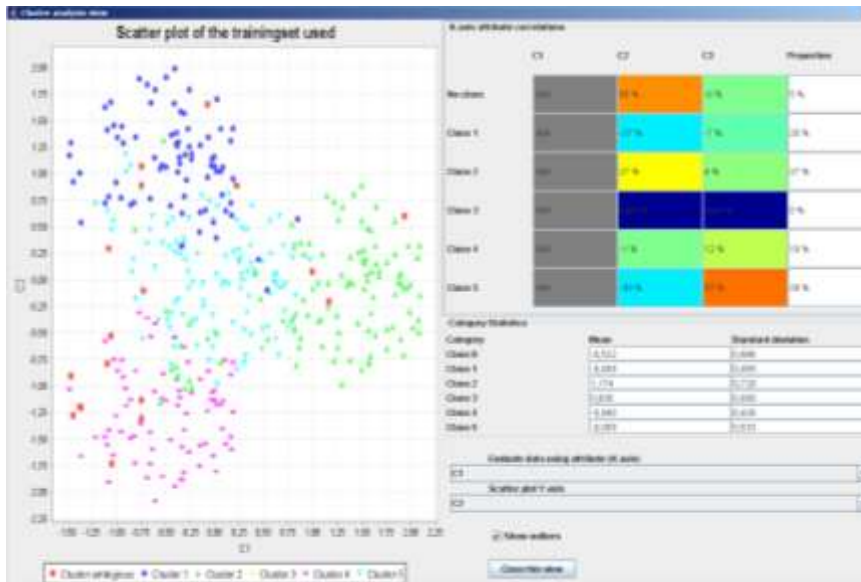


Figure 7 Klusteroinnin merkitys alkuperäisessä data-avaruudessa (Scatter plot)

Kun kartta on saatu jaoteltua mieleisesti voidaan tarkastella miten alkuperäinen data tulee luokitelluksi, jos valitaan jokaista pistettä vastaava lähin kartta-alkio ja sen ryhmä. Yllä on kuva työkalun näkymästä josta käy ilmi huonosti onnistunut klusterointi. Luokan kolme edustajaa ei ole lainkaan ja ilmeisesti olisi tullut tavoitella kahta klusteria viiden sijasta. Punaiset pisteet kuvaavat alkioita, joille ei ole löytynyt tarpeeksi hyvää vastinetta kartan prototyypeistä, joten niiden luokka on epämääräinen.

Klustereiden onnistunut luominen vaatii usein useamman yrityksen. Lopulta voidaan vielä tarkastella ryhmien alkioiden keskiarvoa ja hajontaa tunnuslukujen avulla.

Strategisen mallinnuksen parametrit

Seuraavassa esitellään mahdollisen opetusaineiston parametrit, joiden avulla voitaisiin luoda melko yksinkertaistettu malli verrattuna edellä kuvattuun ideaan. Mukaan on pyritty ottamaan mittauksia mahdollisimman yleispätevistä ja abstrakteista pelihavainnoista, jotka pitäisi löytyä useimmista rahapeleistä. Myöhemmin selitetään valintoja ja esitetään kritiikkiä.

Ideaali tapauksessa malli luodaan erikseen jokaisella pelaajaryhmälle vastaavista opetusnäytteistä. Tällöin osa päättelyn käyttämistä syötteistä, kuten pelihistoriaa kuvaavat (melko vakiot) arvot, voidaan ottaa huomioon vain ryhmittelyssä. Pelaajaryhmien jaottelussa SOM:n avulla voidaan käyttää parametreina:

- Henkilökohtaiset tiedot (ikä, sukupuoli, koulutus)
 - Saatavilla lähinnä testipeleistä
- Kyselyllä kerättävä tieto
 - Pelaatko mielestäsi nettipelejä vähän/normaalisti/paljon ?
 - Otatko helposti riskejä kyllä / ei ?
 - Yms.
- Logeista kerätty tieto
 - Käytetty aika palvelussa / keskimääräisesti pelisessiossa / yms.
 - Sijoitettu rahasumma
 - Riskitasojen frekvenssit
 - Pelisessioiden keskimääräinen väliaika ja lukumäärä

Vaikka pelaajasta kerätty tieto olisi puutteellista, voidaan pelaajaryhmä määrittää SOM avulla, joka on luotu paremmalla aineistolla.

Varsinaista kausikäyttäytymistä analysoiva malli luodaan päätöspuun avulla. Jos testipelaajia ei ole tarpeeksi tai dataa vähän, on parempi luoda yksittäinen malli ja sisällyttää edellä olevat tiedot seuraaviin syötteisiin.

Syöte

- Pelimenestys (10 parametria)
 - Ärsykkeet eli voitot ja häviöt jaotellaan pieniin ja suuriin
 - Ärsykkeiden voimakkuus täytyy täsmentää pelikohtaisesti
 - 4 ärsykettä + 1 neutraali (tasapeli) = 5 luokkaa
 - Lyhytaikainen trendi kerätään ärsykkeiden frekvenssit viimeisten max. 5 pelikierroksen aikana nykyisessä peliputkessa. Peliputki katkeaa kun on vähintään tunnin tauko.
 - Pitempiaikainen trendi kerätään koko peli putken ajalta samalla tavalla.
- Pelihistoria (noin 10 parametria)
 - Eri ärsykkeiden suhteelliset osuudet kuten edellä, mutta nyt myös vanhoista peleistä
 - Pelattujen kierrosten kokonaismäärä
 - Henkilökohtainen palautusprosentti
 - Peliputkien lukumäärä

- Eri pituisten peliputkien määrä
- Harkinta-aika
 - Viimeiseen siirtoon kulunut aika, suhteutettuna keskimääräisellä ajalla **tai** lyhyt/normaali/pitkä pelikohtaisesti

Ennuste

- Pitääkö pelaaja tauon? (2 – 5 luokkaa)
 - Tauko on katkos peliputkien välissä, eli vähintään yksi tunti.
 - Ennustetaan tauon pituus
 - Ei taukoa / lyhyt tauko / normaali tauko / pitkä tauko / ”irtaantuminen”
 - Merkitystä pelin markkinapotentiaalin ja vastuullisuuden arvioinnissa
- Ottaako pelaaja riskin? (2 luokkaa)
 - Kyllä / ei?
 - Esim. tuplaaminen tai keskimääräistä panosta suurempi panos
 - (Kuinka suuren riskin pelaaja ottaa?)
 - Vaikuttaa palautusprosentin arviointiin ja syötetään taktiikka-mallille

Parametrien valinnasta

Valittu tapa pelimenestyksen mittaamiseen on melko yksinkertaistava, koska se ei pyri huomioimaan esimerkiksi rahallisen menetyksen tarkkaa suuruutta. Sanallisilla määreillä on tarkoitus saada mallista helpommin analysoitava jatkossa ja välttää pelikohtaisten piirteiden merkitystä. Toisissa peleissä saattavat kierrokset olla pitempiä, jolloin niillä on luonnollisesti isommat panokset. Toisaalta malliin saadaan myös automaattisesti epälineaarisuutta, joka usein helpottaa luokitusongelmien ratkaisua.

Rajanveto hetkellisen ja pitempiaikaisen pelimenestyksen välillä on hankala vetää, koska yhdessä peliputkessa ei välttämättä ole edes 5 kierrosta koskaan. Tähän tulisi mahdollisesti vetää pelikohtainen raja tai tehdä peliputken määritelmästä joustavampi. Toinen tapa olisi määritellä painokertoimet erityyppisille vanhoille ärsykkeille ja summata nämä. Tämä ei yksistään vielä huomioi peräkkäisiä voittoja ja häviöitä. Kokeellisessa mielessä voisi testata, voitaisiinko pelien aikasarjasta muodostaa eräänlainen novelty-filter, joka hälyttäisi suurella arvolla epätavallisen tilanteen kohdalla. Tähän on käytetty esim. yksinkertaista anti-hebbian oppimissäätöä. Tämä voisi parantaa mallin oppimiskykyä simuloinnin osalta.

Pelihistoria on otettu mukaan, jotta saataisiin kuva miten kokenut ja innokas pelaaja on kyseessä. Tappioita voi olla kertynyt runsaasti esimerkiksi, jos pelaaja on aina jättänyt peliputken vain pariin kierrokseen, ja tämä ehkä vaikuttaa motivaatioon ja pelityyliin.

Lähteet:

http://www.tekes.fi/julkaisut/raportit/43_94/

<http://decisiontrees.net/node/16>