Adaptiivinen oppimismenetelmä käyttäjäprofiilien päivittämiseen

Matematiikan erikoistyöt Mat-1.139

Eerika Savia, 39482a
21.10.1997

Sisältö

1 Johdanto

1.1 Taustaa

Tämä työ on syntynyt osana TKK:n TAI-tutkimuslaitoksen projektia nimeltä SmartPush. Projektissa kehitetään elektronista dokumenttien täsmäjakeluympäristöä, jossa dokumentit voidaan valikoida tilaajille henkilökohtaisesti, kun nämä antavat palautetta lukemistaan dokumenteista. Tällöin voidaan kerätä käyttäjistä kiinnostusprofiili, joka kuvaa painojakaumalla, millaisista dokumenteista käyttäjä on pitänyt.

Lähtöoletuksena on että dokumentteihin on liitetty metadataa, joka kuvaa dokumentin sisältöä kompaktissa muodossa ja jonka avulla dokumentteja voidaan verrata käyttäjäprofiiliin informaation kohdistamiseksi. Profiililla pyritään kuvaamaan käyttäjän mieltymyksiä ja sen tulisi mukautua muuttuviin kiinnostuksen kohteisiin. Käyttäjä voi antaa joko positiivista tai negatiivista palautetta lukemilleen dokumenteille sekä eksplisiittisesti muuttaa profiilinsa painojakaumaa.

Vastaavia dokumenttien täsmäjakeluympäristöjä on toteutettu aiemminkin, mutta aiheen kaupallisuuden vuoksi niiden oppimismenetelmien yksityiskohtia ei ole julkisesti dokumentoitu. Uutta on myös metatiedon käyttö dokumenttien esittämiseen termivektorien sijasta [1].

1.2 Metadatan rakenne

Metadataan kuuluu useita eri komponentteja, joita kutsutaan metadatan dimensioiksi. Osa niistä saa diskreettejä arvoja äärellisestä arvojoukosta (esim. dokumentin lähde) ja osa voidaan esittää hierakian avulla (esim. paikka tai dokumentin aihe). Dokumentin asiasisältö esitetään hierarkian avulla, mihin tässä työssä erityisesti keskitytään.

Dokumentti luokitellaan sisältöhierarkiassa kuuluvaksi sumeasti eri luokkiin siten, että puun lehdissä olevat painot kuvaavat jakaumaa, millä dokumentti kuuluu eri luokkiin. Painot d_k on normeerattu siten, että $\sum_k d_k = 1$. Puun ylemmät solmut ovat yhteenvetoja alipuista siten, että kunkin solmun paino on lapsisolmujen painojen summa. Ylempien solmujen informaatiota voidaan käyttää hyväksi sopivia dokumentteja etsittäessä. Kuvassa 1. on esimerkki dokumentin esitysmuodosta.

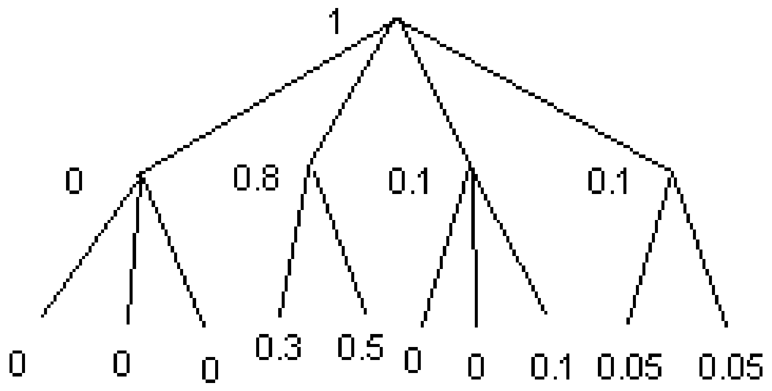

Kuva 1: Dokumentin sisällön esitys puun avulla

1.3 Käyttäjäprofiilin esitys

Käyttäjäprofiilit esitetään samalla tavalla kuin dokumentitkin. Sisältöä esittää siis puu, jossa on kiinnostusjakauma puun lehdissä. Lisäksi käyttäjä voi painottaa profiilissaan eri dimensioita eri tavoin, esimerkiksi asettaa dokumentin lähteen tai uutisarvon aihetta tärkeämmälle sijalle. Painot ovat kuitenkin käyttäjäkohtaisia vakioita (ei riippuvuuksia eri dimensioiden välillä), joten oppiminen voidaan toteuttaa erikseen kussakin dimensiossa. Tässä työssä keskitytään oppimiseen yhden puurakenteisen dimension sisällä.

2 Oppimismenetelmä, 1. versio

2.1 Profiilin päivittäminen

Käyttäjäprofiilia päivitetään automaattisesti aina kun käyttäjä antaa positiivista tai negatiivista palautetta lukemalleen artikkelille. Tämä tapahtuu muuttamalla positiivisessa tapauksessa käyttäjäprofiilia dokumentin suuntaan ja negatiivisessa tapauksessa dokumentista poispäin. Kaikki profiilin päivitys tapahtuu puun lehtitasolla ja vaikutukset summautuvat ylempiin solmuihin, joten jatkossa tarkastellaan vain lehtitason painojen muodostamia vektoreita.

2.2 Positiivinen palaute

Olkoot dokumentin metadatan nollasta poikkeavat painot d_k ja näitä vastaavat painot käyttäjäprofiilissa u_k (osumapainot). Merkitään muita kuin osumapainoja käyttäjäprofiilissa w_s (hutipainot).

$$
\begin{array}{lcccccccc}
\text{käyttäjäprofiili} & (& w_1 & w_2 & u_1 & u_2 & w_3 & w_4 &) \\
 & & & & | & | & & & \\
 & & & & | & | & & & \\
\text{dokumentti} & (& 0 & 0 & d_1 & d_2 & 0 & 0 &)
\end{array}
$$

Kuva 2: Painoille käytetyt merkinnät

$$\sum_k u_k + \sum_s w_s = 1 \quad \wedge \quad \sum_k d_k = 1$$

Olkoon oppimiskerroin $\alpha > 0$ ja oletetaan että $\sum_s w_s > 0$. Lisätään painoa α:n verran osumapainoihin ja vähennetään se hutipainoista siten, että hutipainojen keskinäiset suhteet säilyvät.

$$\begin{cases} u_k := u_k + \alpha\, d_k \\ \\ w_s := w_s - \alpha \frac{w_s}{\sum_l w_l} \end{cases} \tag{1}$$

Painojen suhteet säilyvät, koska alunperin suhde on

$$\frac{w_s}{\sum_l w_l}$$

ja uusille painoille sama suhde on

$$\frac{w_s - \alpha \frac{w_s}{\sum_j w_j}}{\sum_l \left(w_l - \alpha \frac{w_l}{\sum_j w_j}\right)} = \frac{w_s \left(1 - \frac{\alpha}{\sum_j w_j}\right)}{\sum_l w_l \left(1 - \frac{\alpha}{\sum_j w_j}\right)} = \frac{w_s}{\sum_l w_l}.$$

2.3 Oppimiskerroin α

Oppimiskerrointa täytyy rajoittaa siten, että se ei vähennä hutipainoja nollaan asti ja toisaalta ei kasvata yhtäkään osumapainoa yli yhden. Jotta hutipainot säilyisivät positiivisina, täytyy päteä $\forall s$

$$\begin{aligned} & w_s - \alpha \frac{w_s}{\sum_l w_l} = w_s \left(1 - \frac{\alpha}{\sum_l w_l}\right) > 0 \\ \Leftrightarrow \quad & \frac{\alpha}{\sum_l w_l} < 1 \\ \Leftrightarrow \quad & \alpha < \sum_l w_l = 1 - \sum_k u_k \quad . \end{aligned}$$

Jotta yksikään osumapaino ei nousisi yhteen asti, täytyy päteä $\forall k$

$$u_k + \alpha\, d_k < 1 \qquad \Leftrightarrow \qquad \alpha\, d_k < 1 - u_k$$

$$\alpha\, d_k \leq \alpha < \min_k \{1 - u_k\} = 1 - \max_k \{u_k\} \leq 1 - u_k \quad .$$

Siis dokumentista riippumaton minimaalinen ehto on

$$\alpha < 1 - \max_k \{u_k\}$$

Välttämättömiksi ehdoiksi α:lle saatiin

$$\begin{cases} \alpha < 1 - \sum_k u_k \\ \alpha < 1 - \max_k \{u_k\} \end{cases}$$

ja

$$1 - \sum_k u_k \leq 1 - \max_k \{u_k\} \quad ,$$

joten

$$\alpha < 1 - \sum_k u_k = \sum_s w_s \quad . \tag{2}$$

Oppimiskerroin voidaan siis valita

$$\alpha = \beta \sum_s w_s \quad , \tag{3}$$

missä $\beta \in (0, 1)$.

Jos olisi $\beta = 0$, oppimista ei tapahtuisi ollenkaan ja profiili säilyisi ennallaan. Jos $\beta = 1$, se tarkoittaisi, että kaikki kertynyt informaatio menetettäisiin profiilista joka kerta, kun yksi dokumentti arvosteltaisiin. Tällöin hutipainoille saataisiin

$$w_s := w_s - \left(\sum_l w_l \right) \frac{w_s}{\sum_l w_l} = 0 \quad .$$

Jotta profiiliin saataisiin kerättyä informaatiota käyttäjästä, β:n tulisi olla melko lähellä nollaa.

2.4 Esimerkki

Tutkitaan, mitä käyttäjäprofiilille $(\, 0.3 \quad 0.3 \quad 0.4 \quad 0 \quad 0 \quad 0 \,)$ tapahtuu, kun käyttäjä antaa positiivisen palautteen dokumentille $(\, 0 \quad 0 \quad 0.7 \quad 0.3 \quad 0 \quad 0 \,)$ oppimiskertoimilla $\beta = 0.5$.

Hutipainojen summaksi saadaan $\sum_s w_s = 0.3 + 0.3 = 0.6$ ja $\alpha = \beta \cdot 0.6 = 0.3$.

Kaavojen (1) nojalla päivitetty käyttäjäprofiili on

$(\, 0.15 \quad 0.15 \quad 0.61 \quad 0.09 \quad 0 \quad 0 \,)$.

2.5 Erikoistapaus

Jos $\sum_s w_s = 0$ eli alussa tehty oletus ei ole voimassa, oppimisalgoritmi ei voi muuttaa hutipainoja, koska ne ovat jo kaikki nollia. Niinpä osumapainojen osuutta kaikista painoista ei voida kasvattaa vaan ainoastaan niiden keskinäisiä suhteita voidaan muuttaa. Olkoon oppimiskerroin $\lambda > 0$.

$$\begin{cases} u_k := \frac{u_k + \lambda\, d_k}{1+\lambda} \\ \\ w_s := 0 \end{cases} \tag{4}$$

Ainoa rajoitus λ:lle on se, että mikään osumapaino ei saa saada arvokseen 1. Siis $\forall k$ täytyy päteä

$$\begin{aligned} & \frac{u_k + \lambda\, d_k}{1+\lambda} < 1 \qquad \Leftrightarrow \qquad u_k + \lambda\, d_k < 1 + \lambda \\ \Leftrightarrow \qquad & \lambda\,(1 - d_k) > u_k - 1 \quad . \end{aligned}$$

Ainoa epätriviaali tapaus on se, missä jollekin k

$$d_k = 1 \quad \wedge \quad u_k = 1\ .$$

Tässä tilanteessa profiilia ei tule päivittää ollenkaan. λ:n ja β:n merkitykset eivät ole aivan samat, sillä jos $\lambda = 1$, kaikkea kertynyttä informaatiota ei menetetä vaan uudessa profiilissa otetaan dokumentti huomioon yhtä suurella painolla kuin vanha profiili. Uusi profiili on silloin "keskiarvo" vanhasta profiilista ja uudesta dokumentista. Käytännössä haluttu λ:n arvo on siis lähempänä nollaa kuin yhtä.

2.6 Negatiivinen palaute

Koska profiililla pyritään ensisijaisesti esittämään asioita, joista käyttäjä on kiinnostunut, negatiivinen palaute on monimutkaisempi toteuttaa kuin positiivinen. Tarvitaan jonkinlainen negatiivinen profiili, jotta voitaisiin pitää muistissa, millaisista dokumenteista käyttäjä on antanut negatiivista palautetta. Oppimisalgoritmia täytyy muokata, jotta voitaisiin ylläpitää sekä positiivista että negatiivista profiilia.

3 Parannettu oppimismenetelmä

Muunnetaan profiilin esitystä siten, että käyttäjäprofiili koostuukin kahdesta jakaumasta, positiivisesta ja negatiivisesta. Ne eivät voi mennä päällekkäin eli jos toisessa esiintyy nollasta poikkeava paino, niin toisessa on vastaavan komponentin oltava nolla. Kun palautetta annetaan, molempia profiileja voidaan joutua päivittämään.

3.1 Positiivinen palaute

Tarkastellaan dokumenttivektorista vain niitä komponentteja, jotka eroavat nollasta. Merkitään näistä pd_k:lla niitä, jotka osuvat nollasta poikkeaviin painoihin negatiivisessa profiilissa ja p_k:lla negatiivisen profiilin vastaavia painoja (osumapainot). Muut negatiivisen profiilin painot olkoot nimeltään q_k (hutipainot).

Merkitään ud_k:lla niitä dokumentin nollasta poikkeavia painoja, jotka osuvat positiivisen profiilin nollasta poikkeaviin painoihin tai sellaisiin komponentteihin, joissa molemmissa profiileissa on nolla. Merkitään ud_k:ita vastaavia painoja positiivisessa profiilissa u_k (osumapainot) ja muita positiivisen profiilin painoja w_k (hutipainot). Oletetaan lisäksi, että $\sum_s w_s > 0$ ja $\sum_s q_s > 0$.

$$
\begin{array}{llcccccccc}
 & & & w_1 & w_2 & u_1 & u_2 & w_3 & w_4 & \\
\text{käyttäjäprofiili} & + & (& 0.6 & 0 & 0.4 & 0 & 0 & 0 &) \\
 & & & & & | & | & & & \\
\text{dokumentti} & & (& 0 & pd_1 & ud_1 & ud_2 & pd_2 & 0 &) \\
 & & & & | & & | & | & & \\
\text{käyttäjäprofiili} & - & (& 0 & 0.3 & 0 & 0 & 0.2 & 0.5 &) \\
 & & & q_1 & p_1 & q_2 & q_3 & p_2 & q_4 &
\end{array}
$$

Kuva 3: Painoille käytetyt merkinnät, positiivinen palaute

Siis

$$\sum_k u_k + \sum_s w_s = 1 \qquad \text{positiivisen profiilin painot}$$
$$\sum_k p_k + \sum_s q_s = 1 \qquad \text{negatiivisen profiilin painot ja}$$
$$\sum_k ud_k + \sum_l pd_l = 1 \qquad \text{dokumentin painot.}$$

3.1.1 Positiivisen profiilin päivitys

Parannetun oppimismenetelmän periaate on sama kuin luvun 2 algoritmissa, mutta nyt määrä, jolla painoa lisätään osumapainoihin olisikin $\alpha \sum_k ud_k \leq 1$, ellei suoritettaisi normeerausta. Hutipainoista vähennetään yhteensä α painojen suhteessa, samaan tapaan kuin ensimmäisessä algoritmissa.

$$\begin{cases} u_k := u_k + \alpha \frac{ud_k}{\sum_l ud_l} \\ \\ w_s := w_s - \alpha \frac{w_s}{\sum_l w_l} \end{cases} \tag{5}$$

Jälleen vaaditaan, että osumapainot eivät saavuta ykköstä ja hutipainot eivät saavuta nollaa. Jotta hutipainot säilyisivät positiivisina, täytyy päteä $\forall s$

$$\begin{aligned} & w_s - \alpha \frac{w_s}{\sum_l w_l} = w_s \left(1 - \frac{\alpha}{\sum_l w_l}\right) > 0 \\ \Leftrightarrow \quad & \frac{\alpha}{\sum_l w_l} < 1 \\ \Leftrightarrow \quad & \alpha < \sum_l w_l \quad . \end{aligned}$$

Jotta yksikään osumapaino ei nousisi yhteen asti, täytyy päteä $\forall k$

$$\begin{aligned} & u_k + \alpha \frac{ud_k}{\sum_l ud_l} < 1 \qquad \Leftrightarrow \qquad \alpha \frac{ud_k}{\sum_l ud_l} < 1 - u_k \\ \Leftrightarrow \quad & \alpha < \frac{\sum_l ud_l}{ud_k}(1 - u_k) \quad . \end{aligned}$$

Siis välttämättömät ehdot α:lle ovat

$$\begin{cases} \alpha < \sum_l w_l \\ \alpha < \frac{\sum_l ud_l}{ud_k}(1-u_k) \end{cases} .$$

$$\alpha < \sum_l w_l = 1 - \sum_k u_k \leq 1 - \max_k\{u_k\} \leq 1 - u_k \leq \frac{\sum_l ud_l}{ud_k}(1-u_k) \quad ,$$

joten

$$\alpha < \sum_l w_l \quad . \tag{6}$$

Oppimiskerroin voidaan siis valita

$$\alpha = \beta_1 \left(\sum_l w_l \right) \quad , \tag{7}$$

missä $\beta_1 \in (0,1)$ kuten luvun 2 algoritmissa.

3.1.2 Negatiivisen profiilin päivitys

Kun positiivinen palaute osuu johonkin sellaiseen komponenttiin, jossa käyttäjällä on painoa negatiivisessa profiilissaan, täytyy painoa muuttaa positiivisempaan suuntaan eli kohti nollaa. Tämä tarkoittaa painon vähentämistä negatiivisesta profiilista. Vähennetään siis osumapainoista p_k yhteensä α:n verran ja lisätään hutipainohin q_s yhteensä α siten, että hutipainojen keskinäiset suhteet säilyvät.

$$\begin{cases} p_k := p_k - \alpha \frac{pd_k}{\sum_l pd_l} \\ \\ q_s := q_s + \alpha \frac{q_s}{\sum_l q_l} \end{cases} \tag{8}$$

Nyt vaaditaan, että osumapainot eivät mene negatiivisiksi eivätkä hutipainot saavuta ykköstä. Jotta hutipainot säilyisivät yhtä pienempinä, täytyy päteä $\forall s$

$$\begin{aligned} & q_s + \alpha \frac{q_s}{\sum_l q_l} = q_s \left(1 + \frac{\alpha}{\sum_l q_l}\right) < 1 \\ \Leftrightarrow \qquad & \alpha < \sum_l q_l \left(\frac{1}{q_s} - 1\right) \quad , \end{aligned}$$

Koska

$$\alpha < 1 - \sum_l q_l = \sum_l q_l \left(\frac{1}{\sum_l q_l} - 1\right) \leq \sum_l q_l \left(\frac{1}{q_s} - 1\right)$$

saadaan rajoitusehdoksi

$$\alpha < 1 - \sum_l q_l = \sum_k p_k \quad .$$

Jotta osumapainot säilyisivät ei-negatiivisina, täytyy päteä $\forall k$

$$\begin{aligned} & p_k - \alpha \frac{pd_k}{\sum_l pd_l} > 0 \qquad \Leftrightarrow \qquad \alpha \frac{pd_k}{\sum_l pd_l} < p_k \\ \Leftrightarrow \qquad & \alpha < \frac{\sum_l pd_l}{pd_k} p_k \quad . \end{aligned}$$

$$\alpha < \min_k \{p_k\} \leq \frac{\sum_l pd_l}{pd_k} \min_k \{p_k\} \leq \frac{\sum_l pd_l}{pd_k} p_k \quad \forall k$$

Siis välttämättömät ehdot α:lle

$$\begin{cases} \alpha < \sum_k p_k \\ \alpha < \min_k \{p_k\} \end{cases}$$

$$\alpha < \min_k \{p_k\} \leq \sum_k p_k \quad ,$$

joten minimaalinen ehto α:lle on

$$\alpha < \min_k\{p_k\} \quad . \tag{9}$$

Oppimiskerroin voidaan siis valita

$$\alpha = \beta_2 \min_k\{p_k\} \quad , \tag{10}$$

missä $\beta_2 \in (0,1)$.

3.1.3 Esimerkki

Tutkitaan, mitä käyttäjäprofiilille $P_+ = (\ 0.6 \quad 0 \quad 0.4 \quad 0 \quad 0 \quad 0\ )$, $P_- = (\ 0 \quad 0.3 \quad 0 \quad 0 \quad 0.2 \quad 0.5\ )$ tapahtuu, kun käyttäjä antaa positiivisen palautteen dokumentille $(\ 0 \quad 0 \quad 0.2 \quad 0.4 \quad 0.2 \quad 0.2\ )$ oppimiskertoimilla $\beta_1 = \beta_2 = 0.5$.

Hutipainojen summaksi positiivisessa profiilissa saadaan $\sum_s w_s = 0.6$ ja $\min_k\{p_k\} = 0.2$.

Kaavojen (5) ja (8) nojalla päivitetty käyttäjäprofiili on

$P_+ = (\ 0.3 \quad 0 \quad 0.5 \quad 0.2 \quad 0 \quad 0\ )$, $P_- = (\ 0 \quad 0.4 \quad 0 \quad 0 \quad 0.15 \quad 0.45\ )$

3.1.4 Erikoistapaukset

Jos $\sum_s w_s = 0$ tai $\sum_s q_s = 0$ eli alussa tehdyt oletukset eivät ole voimassa, oppimisalgoritmi ei voi muuttaa hutipainoja, koska ne ovat jo nollassa. Niinpä osumapainojen osuutta kaikista painoista ei voida muuttaa vaan ainoastaan niiden keskinäisiä suhteita.

Olkoon oppimiskerroin $0 < \lambda < 1$.

Positiivinen profiili, kun $\sum_s w_s = 0$

$$\begin{cases} u_k := \frac{u_k + \lambda \frac{ud_k}{\sum_l ud_l}}{1+\lambda} \\ \\ w_s := 0 \end{cases} \tag{11}$$

Ainoa rajoitus λ:lle on se, että mikään osumapaino ei saa saada arvokseen 1. Siis täytyy päteä $\forall k$

$$\begin{aligned} & \frac{u_k + \lambda \frac{ud_k}{\sum_l ud_l}}{1+\lambda} < 1 \\ \Leftrightarrow \quad & u_k + \lambda \frac{ud_k}{\sum_l ud_l} < 1 + \lambda \\ \Leftrightarrow \quad & \lambda \left(1 - \frac{ud_k}{\sum_l ud_l} \right) > u_k - 1 \quad . \end{aligned}$$

Ainoa epätriviaali tapaus on se, missä jollekin k

$$ud_k = \sum_l ud_l \quad \wedge \quad u_k = 1 \quad .$$

Tässä tilanteessa profiilia ei tule päivittää ollenkaan, koska profiilissa on jo maksimaalinen kiinnostus dokumentin aiheeseen.

Negatiivinen profiili, kun $\sum_s q_s = 0$

$$\begin{cases} p_k := \frac{p_k - \lambda \frac{pd_k}{\sum_l pd_l}}{1-\lambda} \\ \\ q_s := 0 \end{cases} \tag{12}$$

Ainoa rajoitus λ:lle on se, että mikään osumapaino ei saa saada negatiivista arvoa. Siis pitää päteä $\forall k$

$$\begin{aligned} & p_k - \lambda \frac{pd_k}{\sum_l pd_l} > 0 \\ \Leftrightarrow \quad & \lambda < p_k \frac{\sum_l pd_l}{pd_k} \quad . \end{aligned}$$

Huomataan, että

$$\frac{\sum_l pd_l}{pd_k} \geq 1 \quad \text{ja} \quad p_k \geq \min_l \{p_l\} \quad ,$$

joten riittävä ehto λ:lle on

$$\lambda < \min_l \{p_l\} \quad ,$$

joten voidaan valita $\lambda = \beta_2 \min_l \{p_l\}$, missä $\beta_2 \in (0, 1)$.

3.2 Negatiivinen palaute

Negatiivinen palaute tehdään täysin peilikuvana positiiviselle palautteelle. Tarkastellaan dokumentin profiilista vain niitä komponentteja, jotka eroavat nollasta. Merkitään näistä ud_k:lla niitä, jotka osuvat nollasta poikkeaviin painoihin positiivisessa profiilissa ja u_k:lla negatiivisen profiilin vastaavia painoja. Muut positiivisen profiilin painot olkoot nimeltään w_k.

Merkitään pd_k:lla niitä dokumentin painoja, jotka osuvat negatiivisen profiilin nollasta poikkeaviin painoihin tai sellaisiin komponentteihin, joissa molemmissa profiileissa on nolla. Painoja pd_k vastaavat painot negatiivisessa profiilissa olkoot p_k ja muut negatiivisen profiilin painot q_k. Siis

$$
\begin{array}{llccccccccc}
 & & & w_1 & w_2 & u_1 & w_3 & w_4 & w_5 & \\
\text{käyttäjäprofiili} & + & (& 0.6 & 0 & 0.4 & 0 & 0 & 0 &) \\
 & & & & & | & | & & & \\
\text{dokumentti} & & (& 0 & pd_1 & ud_1 & pd_2 & pd_3 & 0 &) \\
 & & & & | & & | & | & & \\
\text{käyttäjäprofiili} & - & (& 0 & 0.3 & 0 & 0 & 0.2 & 0.5 &) \\
 & & & q_1 & p_1 & q_2 & p_2 & p_3 & q_3 &
\end{array}
$$

Kuva 4: Painoille käytetyt merkinnät, negatiivinen palaute

3.2.1 Positiivisen profiilin päivitys

$$
\begin{cases} u_k := u_k - \alpha \frac{ud_k}{\sum_l ud_l} \\ \\ w_s := w_s + \alpha \frac{w_s}{\sum_l w_l} \quad , \end{cases} \tag{13}
$$

mistä saadaan α:lle rajoitteeksi

$$
\alpha < \min_k \{u_k\} \quad , \tag{14}
$$

joten oppimiskerroin voidaan valita

$$
\alpha = \beta_2 \min_k \{u_k\} \quad , \tag{15}
$$

missä $\beta_2 \in (0,1)$. (Tässä on oletettu, että $\sum_s w_s > 0$.)

3.2.2 Negatiivisen profiilin päivitys

$$\begin{cases} p_k := p_k + \alpha \frac{pd_k}{\sum_l pd_l} \\ \\ q_s := q_s - \alpha \frac{q_s}{\sum_l q_l} \quad , \end{cases} \tag{16}$$

missä oppimiskertoimen välttämätön ehto on

$$\alpha < \sum_l q_l \quad . \tag{17}$$

Valitaan siis

$$\alpha = \beta_1 \left(\sum_l q_l \right) \quad , \tag{18}$$

missä $\beta_1 \in (0, 1)$. (Oletuksella $\sum_l q_l > 0$)

3.2.3 Erikoistapaukset

Jos $\sum_s w_s = 0$ tai $\sum_s q_s = 0$ eli edellä tehdyt oletukset eivät ole voimassa, oppimisalgoritmi ei voi muuttaa hutipainoja, koska ne ovat jo nollia. Vain osumapainojen keskinäisiä suhteita voidaan muuttaa.

Olkoon oppimiskerroin $0 < \lambda < 1$.

Negatiivinen profiili, kun $\sum_s q_s = 0$

$$\begin{cases} p_k := \frac{p_k + \lambda \frac{pd_k}{\sum_l pd_l}}{1+\lambda} \\ \\ q_s := 0 \quad , \end{cases} \tag{19}$$

missä λ:lle pitää päteä

$$\lambda \left(1 - \frac{pd_k}{\sum_l pd_l} \right) > p_k - 1 \quad .$$

Ainoa epätriviaali tapaus on se, missä jollekin k

$$pd_k = \sum_l pd_l \quad \wedge \quad p_k = 1 \quad .$$

Tässä tilanteessa profiilia ei tule päivittää ollenkaan.

Positiivinen profiili, kun $\sum_s w_s = 0$

$$\begin{cases} u_k := \frac{u_k - \lambda \frac{ud_k}{\sum_l ud_l}}{1-\lambda} \\ \\ w_s := 0 \end{cases} \tag{20}$$

Ainoa rajoitus λ:lle on se, että mikään osumapaino ei saa saada negatiivista painoa. Ehdoksi saadaan $\forall k$

$$\lambda < u_k \frac{\sum_l ud_l}{ud_k} \quad ,$$

joten riittävä ehto λ:lle on

$$\lambda < \min_l \{u_l\} \quad .$$

Voidaan siis valita $\lambda = \beta_2 \min_l\{u_l\}$, missä $\beta_2 \in (0, 1)$.

3.2.4 Esimerkki

Tutkitaan, mitä käyttäjäprofiilille $P_+ = (\ 0.6 \quad 0 \quad 0.4 \quad 0 \quad 0 \quad 0\ )$, $P_- = (\ 0 \quad 0.2 \quad 0 \quad 0 \quad 0.3 \quad 0.5\ )$ tapahtuu, kun käyttäjä antaa negatiivisen palautteen dokumentille $(\ 0 \quad 0.4 \quad 0.2 \quad 0 \quad 0.2 \quad 0.2\ )$ oppimiskertoimilla $\lambda = \beta_2 = 0.5$.

Hutipainojen summaksi negatiivisessa profiilissa saadaan $\sum_s q_s = 0$ ja $\min_k\{u_k\} = 0.4$, joten $\alpha = \beta_2 \cdot 0.4 = 0.2$.

Kaavojen (13) ja (19) nojalla päivitetty käyttäjäprofiili on

$P_+ = (\ 0.8 \quad 0 \quad 0.2 \quad 0 \quad 0 \quad 0\ )$, $P_- = (\ 0 \quad 0.3 \quad 0 \quad 0 \quad 0.28 \quad 0.42\ )$

3.3 Painon siirtyminen nollan yli

Jos positiivisen profiilin jokin komponentti vähenee annettua kynnysarvoa lähemmäksi nollaa käyttäjän antaman negatiivisen palautteen vuoksi, se pyöristetään nollaksi. Samalla muita positiivisen profiilin painoja tasoitetaan siten, että niiden keskinäiset suhteet ja painojen summa (1) säilyvät. Kun sama komponentti saa seuraavan kerran negatiivista palautetta, sen kohdalle tulee painoa negatiiviseen profiiliin. Jos jokin komponentti vähenee alle kynnysarvon positiivisen palautteen yhteydessä, hutipainona, pyöristystä ei tehdä.

Vastaavasti menetellään, kun negatiivisessa profiilissa jokin komponentti alittaa kynnysarvon positiivisen palautteen takia.

3.4 Kaksi oppimiskerrointa

Kaavoissa esiintyvät β_1 ja β_2 vaikuttavat eri tavoin, koska toinen kertoo erästä painojen summaa ja toinen kertoo erästä minimipainoa. β_2:n on yleensä syytä olla suurempi kuin β_1. (Ks. s.24-25)

3.5 Avoimia kysymyksiä

- Minkä funktioina oppimiskertoimien tulisi määräytyä ? Niiden ei pitäisi olla edes käyttäjäkohtaisesti vakioita. Esimerkiksi jo arvosteltujen dokumenttien määrä voisi vaikuttaa oppimiskertoimiin tai käyttäjän antaman palautteen tiheys. Oppimiskertoimien keskinäisen suhteen pitäisi todennäköisesti myös määräytyä jotenkin tilanteesta riippuen.

- Minkä asioiden tulisi vaikuttaa nollan ohituksessa käytettävään kynnysarvoon ? Sen pitäisi riippua ainakin keskimääräisestä profiilin komponenttien suuruudesta, mikä saattaa olla erilainen jo saman käyttäjän positiivisessa ja negatiivisessa profiilissa.

- Käyttäjälle pyritään hakemaan dokumentteja, jotka vastaavat mahdollisimman hyvin käyttäjän positiivista profiilia. Miten negatiivista profiilia käytetään suodattimena etsinnässä löydetyille dokumenteille ?

- Esimerkki ongelmatilanteesta : $P_+ = (0, 0.3, 0.7, 0)$, $\quad P_- = (1, 0, 0, 0)$, dokumentti $d = (1, 0, 0, 0)$ ja annetaan positiivinen palaute. Mitään ei ole tehtävissä, koska jos P_-:n ensimmäistä painoa halutaan pienentää, on kasvatettava jotain P_-:n nollassa olevaa painoa.

4 Testaus

Menetelmää testattiin Mathematicalla toteutetulla ohjelmalla. Parannetun menetelmän koeajoissa kynnysarvona nollan ylittämiseen/alittamiseen on käytetty arvoa 0.001.

4.1 1. Menetelmä

Oppimiskertoimen vaikutus

Kuvasarjassa 1. näkyy, miten käyttäjäprofiili muuttuu, kun positiivinen palaute annetaan kerran kuvan dokumentille oppimiskertoimen arvoilla $\beta = 1$, $\beta = 0.5$ ja $\beta = 0$. Kun $\beta = 1$, käyttäjäprofiili muuttuu täysin dokumentin kaltaiseksi ja kun $\beta = 0$, päivitystä ei tapahdu ollenkaan.

Kuvasarja 1.

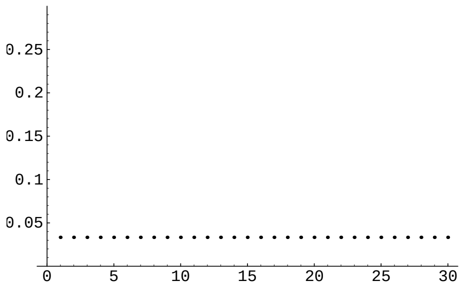

(a) Alkuprofiili

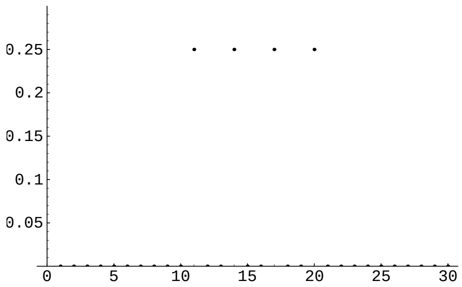

(b) Dokumentti

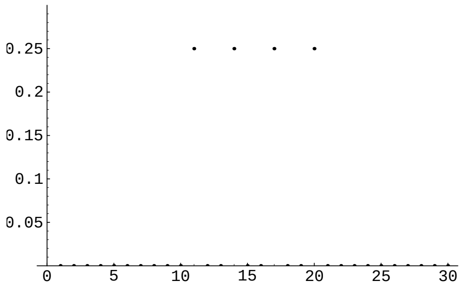

(c) $\beta = 1$

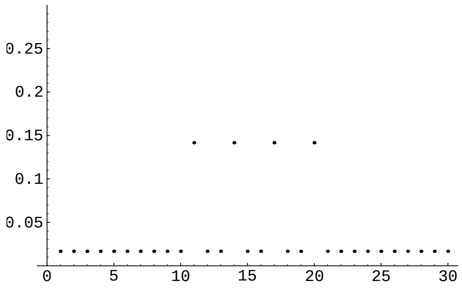

(d) $\beta = 0.5$

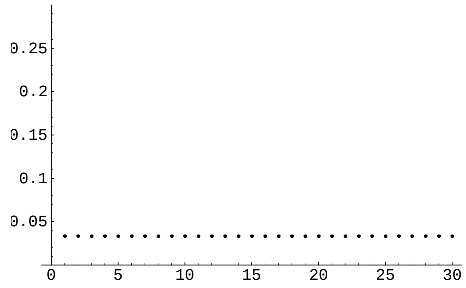

(e) $\beta = 0$

Palautteen järjestyksen vaikutus

Kuvasarjoissa 2. ja 3. näkyy, miten annetun palautteen järjestys vaikuttaa profiiliin. Vanhempi palaute jää vähemmälle painolle, kuin tuoreempi palaute. Kuvasarjoissa 2. ja 3. $\beta = 0.5$, mikä aiheuttaa verrattain suuria muutoksia profiiliin, kun taas kuvasarjassa 4. $\beta = 0.01$ eikä alkuprofiilin informaatiota menetetä kokonaan.

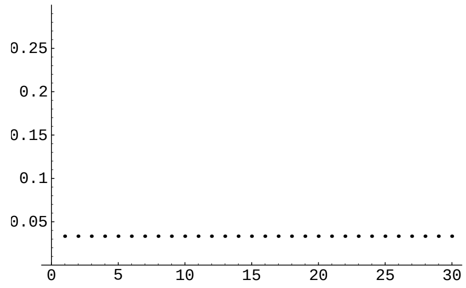

(a) Alkuprofiili

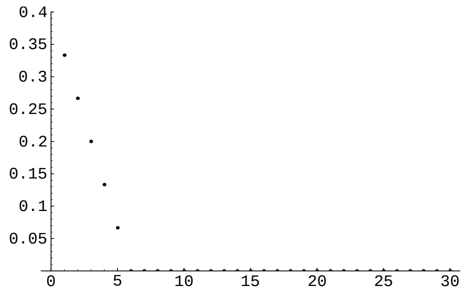

(b) Dokumentti 1

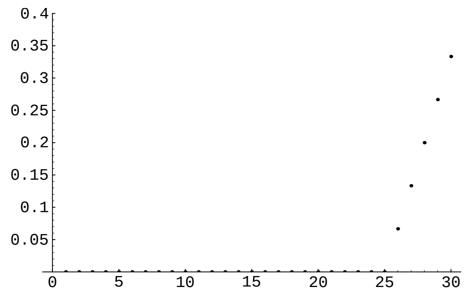

(c) Dokumentti 2

Kuvasarja 2.

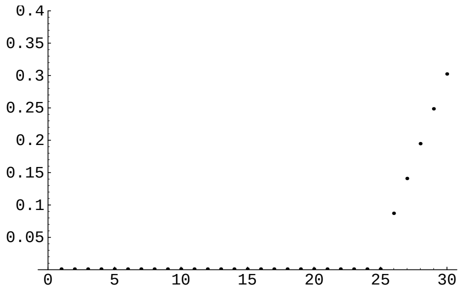

(d) 5 kertaa dokumentti 2, $\beta = 0.5$

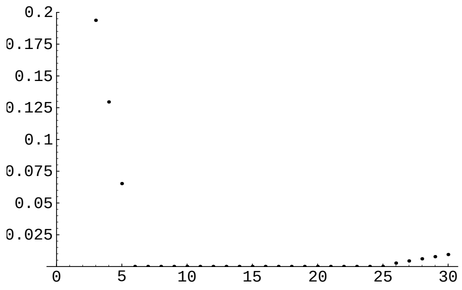

(e) 5 kertaa dokumentti 1, $\beta = 0.5$

Kuvasarja 3.

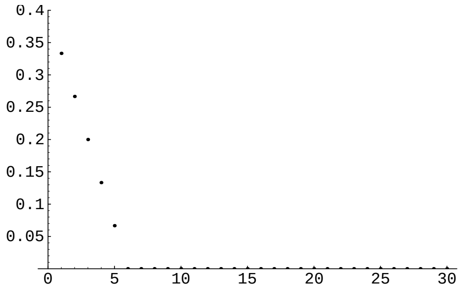

(a) Dokumentti 1

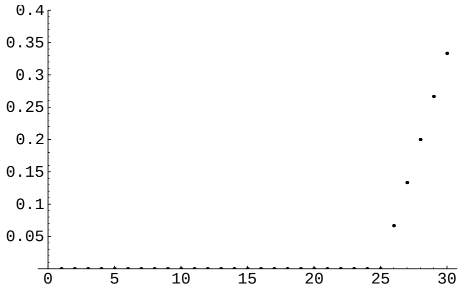

(b) Dokumentti 2

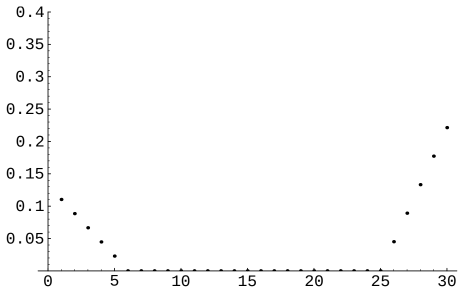

(c) Vuorotellen dokumentti 1 ja dokumentti 2, 5 kertaa, $\beta = 0.5$

Kuvasarja 4.

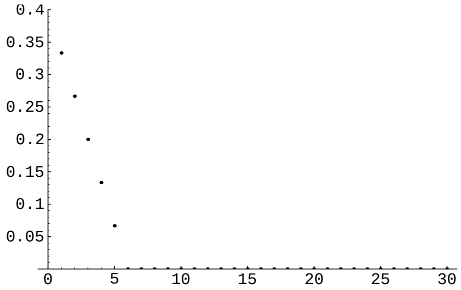

(a) Alkuprofiili

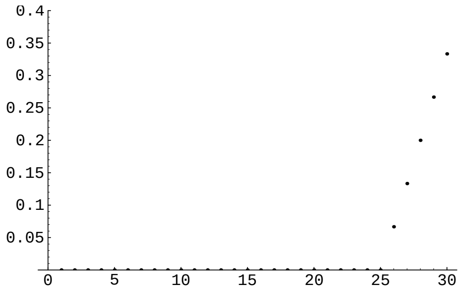

(b) Dokumentti 1

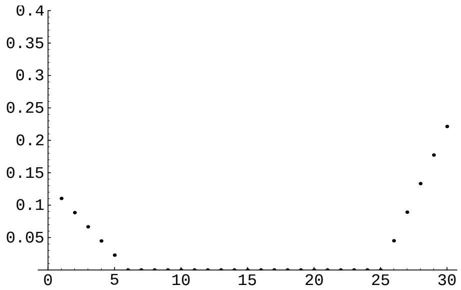

(c) Doumentti 2

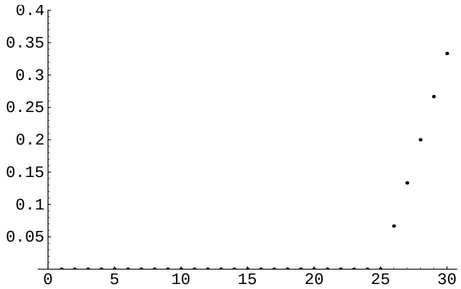

(d) 20 kertaa dokumentti 2, $\beta = 0.01$

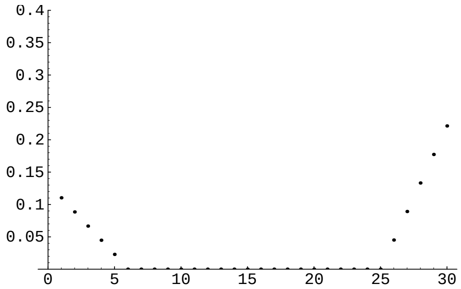

(e) 20 kertaa dokumentti 1, $\beta = 0.01$

4.2 Parannettu menetelmä

Negatiivinen palaute

Kuvasarjassa 5. annetaan negatiivista palautetta dokumentille 3 a) 40 b) 140 kertaa. Oppimiskertoimet ovat $\beta_1 = 0.01$ ja $\beta_2 = 0.1$. Positiivinen profiili on kuvattu x-akselin yläpuolelle ja negatiivinen profiili alapuolelle.

Kuvasarja 5.

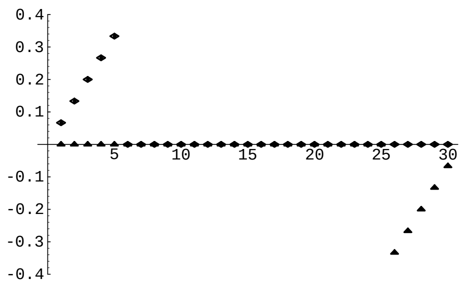

(a) Alkuprofiili

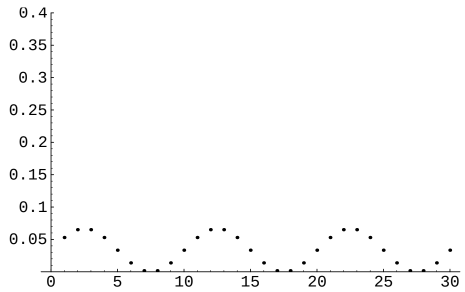

(b) Dokumentti 3

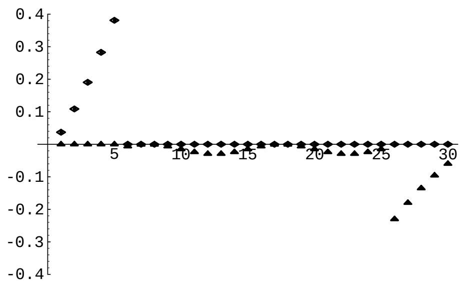

(c) Negatiivinen palaute 40 kertaa dokumentille 3,$\beta_1 = 0.01$, $\beta_2 = 0.01$

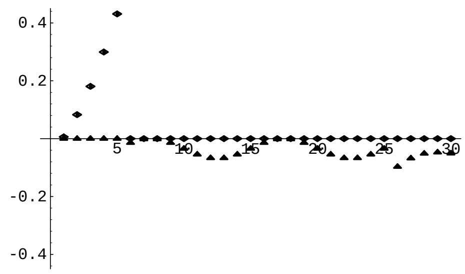

(d) Negatiivinen palaute 140 kertaa dokumentille 3 (alkuprofiilista lähtien) $\beta_1 = 0.01$, $\beta_2 = 0.01$

Nollan alittaminen

Kuvasarjassa 6. näytetään yksinkertaisella esimerkillä, miten komponentin paino voi siirtyä positiivisesta profiilista negatiiviseen profiiliin. Oppimiskertoimina on käytetty $\beta_1 = \beta_2 = 0.5$.

Kuvasarja 6.

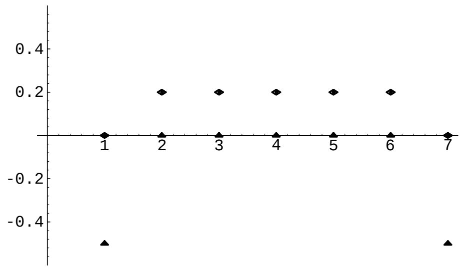

(a) Alkuprofiili

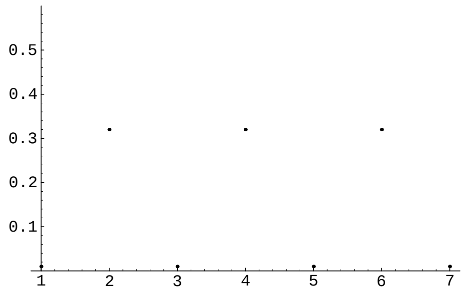

(b) Dokumentti 4

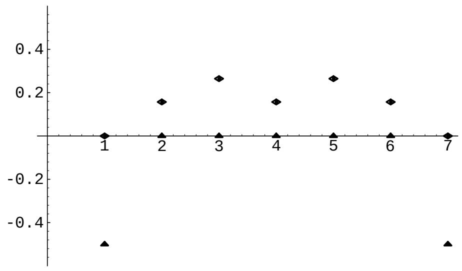

(c) Negatiivinen palaute 3 kertaa dokumentille 4

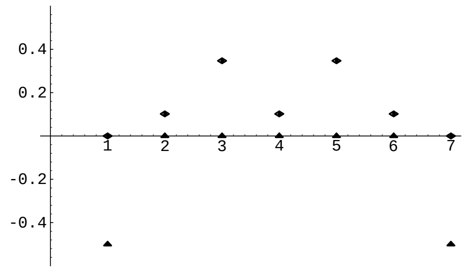

(d) Negatiivinen palaute 7 kertaa dokumentille 4

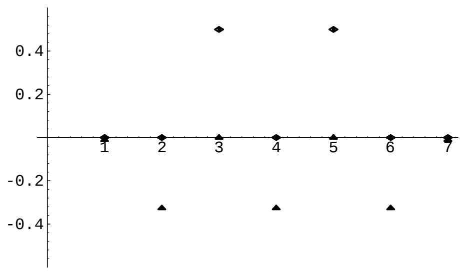

(e) Negatiivinen palaute 70 kertaa dokumentille 4

Kaksi oppimiskerrointa tarpeen

Kuvasarjassa 7. havainnollistetaan oppimiskerrointen β_1 ja β_2 välistä eroa. $\alpha_1 = \beta_1 \cdot (\text{summa hutipainoista})$, kun taas $\alpha_2 = \beta_2 \cdot (\text{minimi osumapainoista})$

Kuvasarja 7.

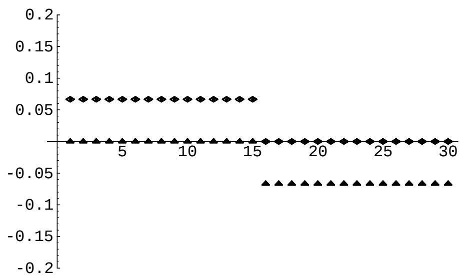

(a) Alkuprofiili

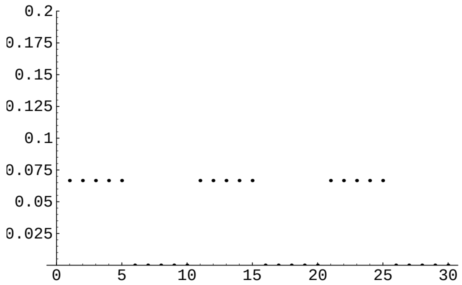

(b) Dokumentti 5

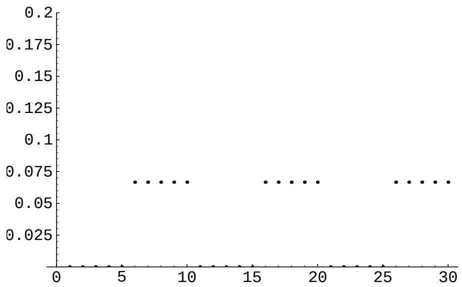

(c) Dokumentti 6

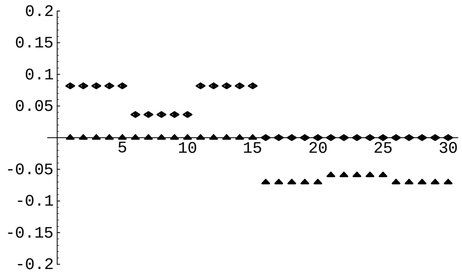

(d) Ensin positiivinen palaute 60 kertaa dokumentille 5 (epäsymmetrinen vaikutus)

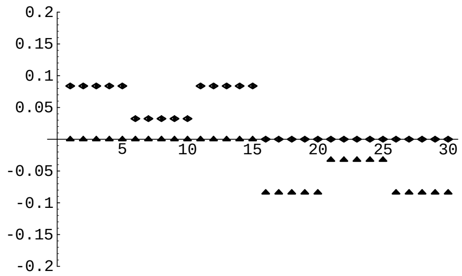

(e)

(f) Sen jälkeen negatiivinen palaute 60 kertaa dokumentille 6 (tasoittava vaikutus)

Kuvasarjassa 8. on muuten samanlainen ajo kuin kuvasarjassa 7. mutta oppimiskertoimet on valittu $\beta_1 = 0.01$ ja $\beta_2 = 0.1$.
(Arvot haettu kokeilemalla.)

Kuvasarja 8.

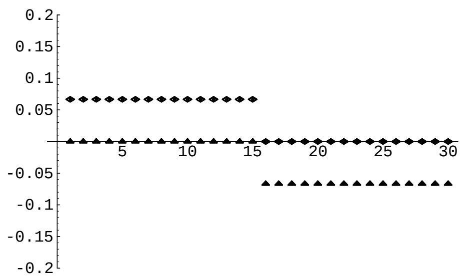

(a) Alkuprofiili

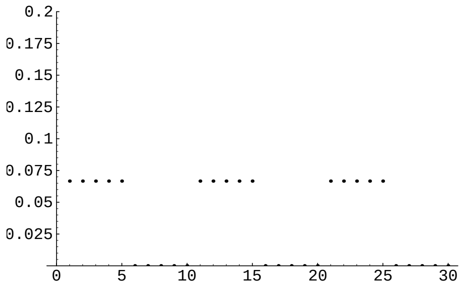

(b) Dokumentti 5

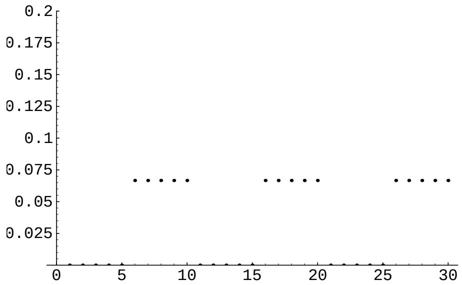

(c) Dokumentti 6

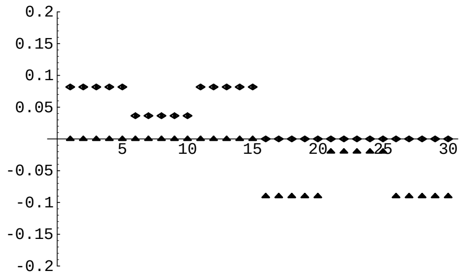

(d) Ensin positiivinen palaute 60 kertaa dokumentille 5

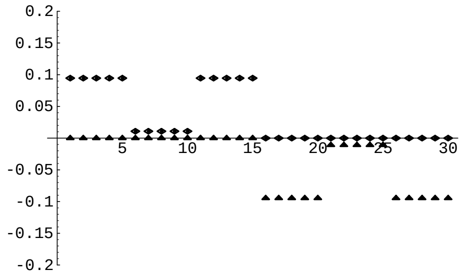

(e) Sen jälkeen negatiivinen palaute 60 kertaa dokumentille 6

Viitteet

[1] Sheth, Beerud (1994). A Learning Approach to Personalized Information Filtering, M.I.T.

[2] McElligott, Michael, Sorensen, Humphrey (1994). An Evolutionary Connectionist Approach to Personal Information Filtering, Irish Neural Networks Conference '94.

[3] Shardanand U., Maes P.(1995). Social Information Filtering : Algorithms for Automating "Word of Mouth", CHI'95.

[4] Metral Max(1993). Design of a Generic Learning Interface Agent, M.I.T.

[5] Russell, S., Norvig P., (1995). Artificial Intelligence - A Modern Approach, Prentice Hall.

A 1. Menetelmä

Positiivinen pakaute $\beta = 0.01$

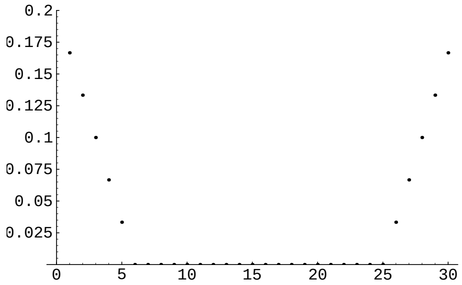

(a) Alkuprofiili

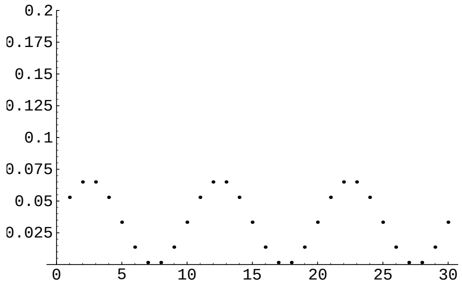

(b) Dokumentti 3

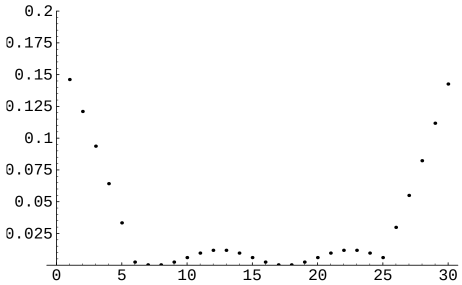

(c) 20 kierrosta

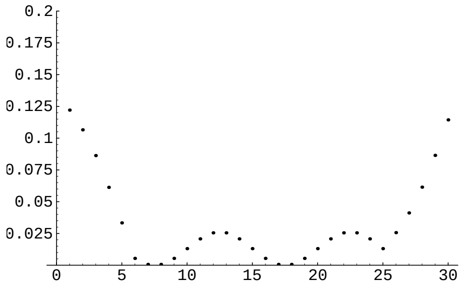

(d) 50 kierrosta

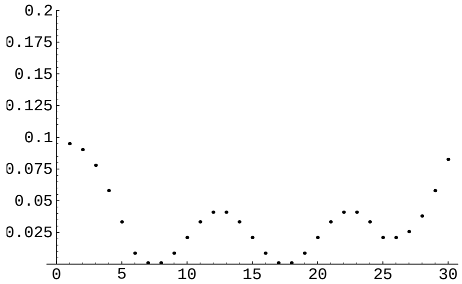

(e) 100 kierrosta

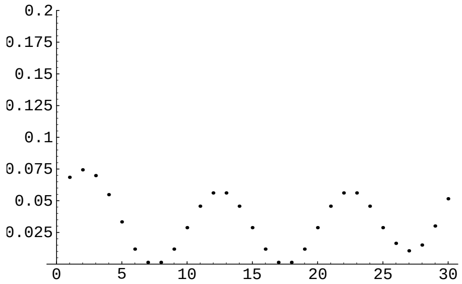

(f) 200 kierrosta

B Parannettu menetelmä

Kuvasarja B1 Negatiivinen palaute $\beta_1 = 0.01, \beta_2 = 0.1$

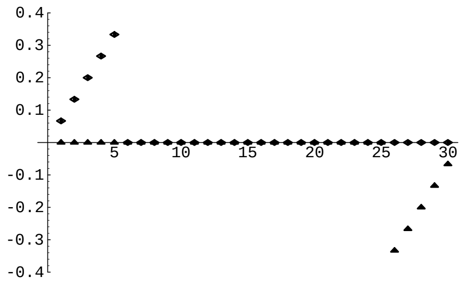

(a) Alkuprofiili

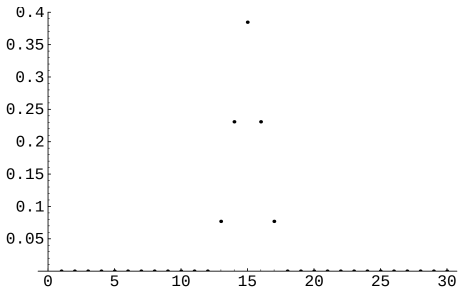

(b) Dokumentti 7

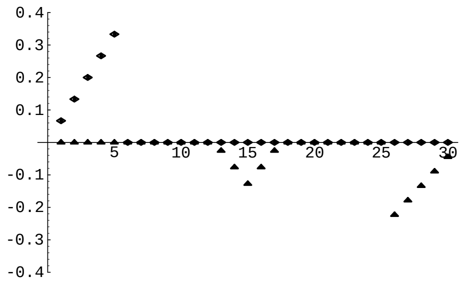

(c) 40 kierrosta

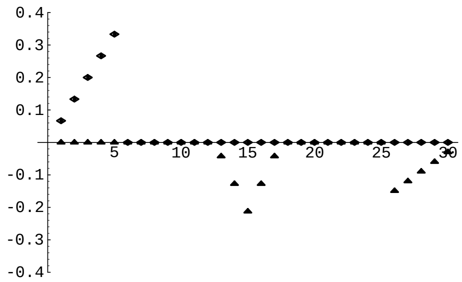

(d) 80 kierrosta

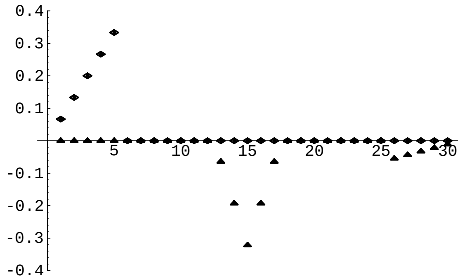

(e) 180 kierrosta

Kuvasarja B2.

Vuorotellen dokumentti 5 ja dokumentti 6, 40 kertaa, $\beta_1 = \beta_2 = 0.01$

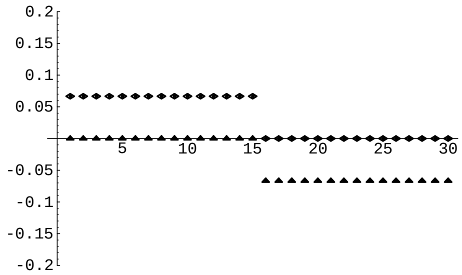

(a) Alkuprofiili

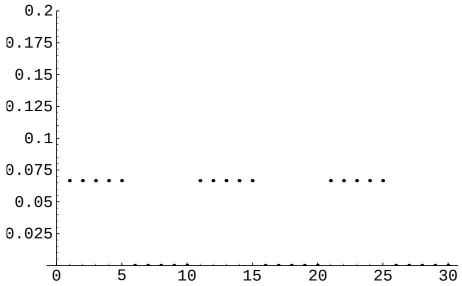

(b) Dokumentti 5

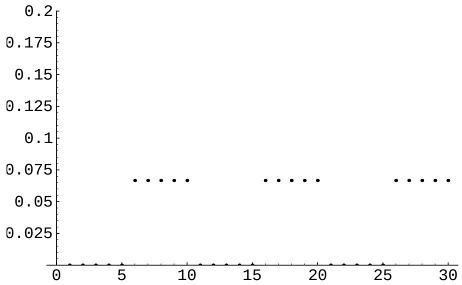

(c) Dokumentti 6

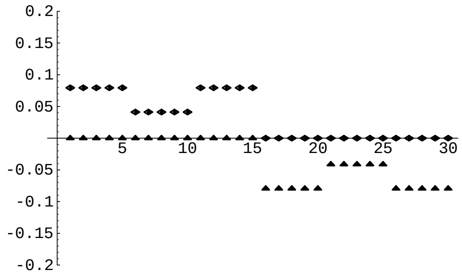

(d)

Kuvasarja B3. Negativinen palaute, $\beta_1 = 0.01,\ \beta_2 = 0.1$.

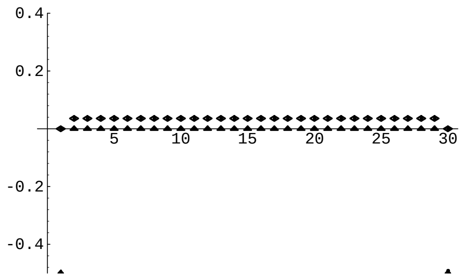

(a) Alkuprofiili

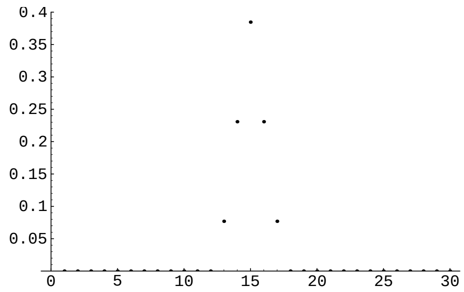

(b) Dokumentti 7

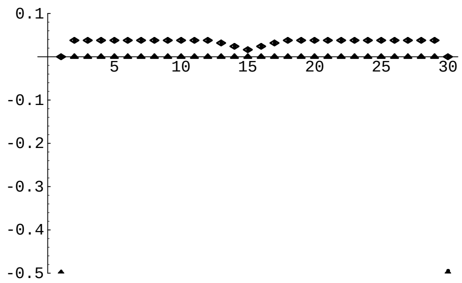

(c) 20 kierrosta

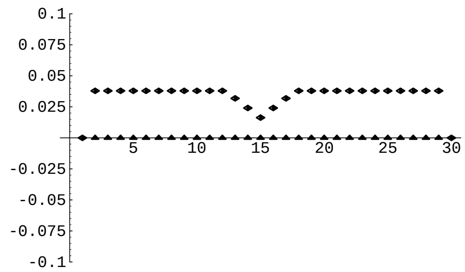

(d) 20 kierrosta, suurennos

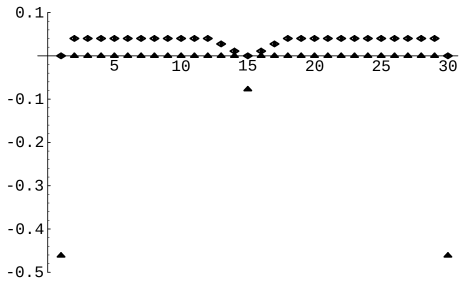

(e) 100 kierrosta

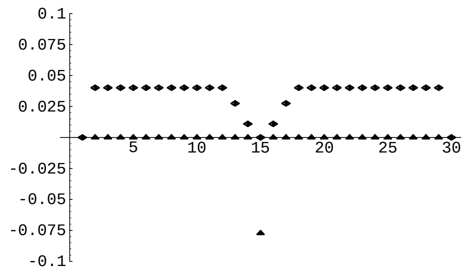

(f) 100 kierrosta suurennos

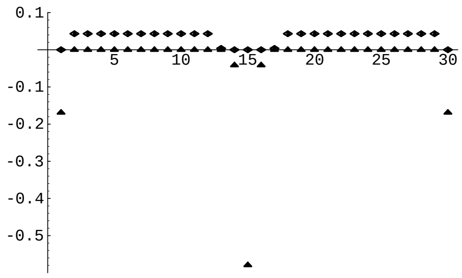

(g) 200 kierrosta

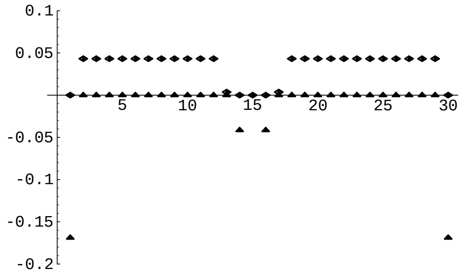

(h) 200 kierrosta, suurennos

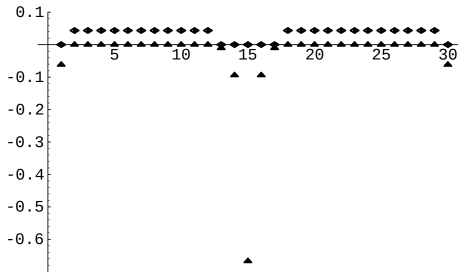

(i) 300 kierrosta