

Kolmiulotteisen kiihtyvyyssanturin ja älykkäiden laskentamenetelmien käyttö lypsylehmien käyttäytymisen mallintamisessa

Paula Martiskainen¹⁾, Jukka-Pekka Skön²⁾, Mikko Järvinen¹⁾, Jarkko Tiirikainen²⁾, Mikko Kolehmainen²⁾, Jaakko Mononen¹⁾

¹⁾Itä-Suomen yliopisto, Biotieteiden laitos, PL 1627, 70211 Kuopio, etunimi.sukunimi@uef.fi

²⁾ Itä-Suomen yliopisto, Ympäristötieteen laitos, PL 1627, 70211 Kuopio, etunimi.sukunimi@uef.fi

Tiivistelmä

Karjakokojen kasvaessa on pakko turvautua yhä useammin eläintuotannon pitkälle menevään automatisointiin. Kiihtyvyyssantureiden avulla voi olla mahdollista seurata tarkasti myös eläinten käyttäytymistä ja siten tehdä arvioita eläinten hyvinvoinnin tasosta. Tutkimme kiihtyvyyssanturin käyttömahdollisuuksia lypsylehmien käyttäytymisen mittaamisessa.

Tutkimuksessa käytettiin kolmiulotteista kiihtyvyyssanturia (ADXL330, Analog Devices), joka kiinnitettiin 30 lypsylehmän kaulapannan niskapuolelle. Kiihtyvyyttä mitattiin 10 Hz taajuudella. Kiihtyvyyssarvojen tulkitsemista varten lehmien käyttäytymistoimintoista tehtiin havaintoja suoraan navetassa sekä videolta. Analysoitavia käyttäytymistoimintoja olivat seisominen (havaintojen lukumäärä 1356; havainnoitujen lehmien lukumäärä 30), makaaminen (1150; 30), makuulla märehtiminen (1411; 30), säilörehun syöminen (1017; 30), käveleminen normaalisti (568; 6), ontuminen (571; 9), makuulle laskeutuminen (63; 18) ja ylös nouseminen (101; 18). Käyttäytymishavaintojen kanssa samanaikaisesti kerätyistä kiihtyvyyssmittauksista laskettiin 28 piirrettä (keskiarvo, keskihajonta, vinous, huipukkuus, maksimiarvo, minimiarvo ja energia kullekin kiihtyvyyssanturin kolmelle akselille; akselien kiihtyvyyssarvojen väliset korrelaatiot ja vektorin pituus) käyttäen laskennassa 10 sekunnin aikaikkunaa. Piirrevektorien saamat arvot skaalattiin nollan ja yhden välille. Aineisto luokiteltiin tukivektorikoneella (*Support vector machine*) yhdistämällä kahdeksan kaksiluokkaista luokittelijaa. Luokittelijan opetuksessa käytettiin 70 % ja testauksessa 30 % aineistosta.

Luokittelumallien ulkoinen tarkkuus (*accuracy*) oli kaikilla malleilla hyvä (87–99 %). Luokittelun onnistumista tarkasteltiin sisäisen tarkkuuden (*precision*) avulla, joka kertoo, kuinka suuren osuuden esimerkiksi havaituista seisomistapauksista malli myös luokittelee seisomiseksi. Luokittelumalli tunnisti käyttäytymistoimintoista parhaiten makuulla märehtimisen (tehdystä havainnoista 86 % luokiteltiin oikein), makaamisen (83 %), säilörehun syöminen (81 %) ja normaalisti kävelemisen (79 %). Hiukan heikommin tunnistettiin ontuminen (66 %) ja seisominen (65 %). Makuulle laskeutumisen (0 %) ja ylös nousemisen (29 %) tunnistaminen aineistosta ei onnistunut mallintamiseen käytettyjen havaintojen vähäisen lukumäärän vuoksi.

Käyttämämme luokittelumalli ei näytä sellaisenaan sopivan lyhytkestoisten käyttäytymistoimintojen mallintamiseen. Käytetyt luokittelumallit vaativatkin vielä kehittämistä luotettavampien tulosten saavuttamiseksi. Kiihtyvyyssanturin hyödyntäminen lypsylehmien käyttäytymisen seurannassa on tulostemme perusteella kuitenkin mahdollista.

Asiasanat: lypsykarja, naudat, kiihtyvyyssanturi, tukivektorikone, käyttäytymisen mittaaminen

Johdanto

Eläinten käyttäytyminen on eräs eniten käytetyistä ja ehkä herkimmistäkin eläinten hyvinvoinnin mittareista (esim. Krohn & Munksgaard 1993, Haley ym. 2001). Käyttäytymisen seuranta ja mittaaminen tilatasolla on kuitenkin erittäin hankalaa ja kallista, sillä se vie aikaa ja vaatii runsaasti työvoimaa. Käyttäytymisen seuranta on pyritty helpottamaan erilaisilla automaattisilla mittaustilanteilla (esim. Scheibe ym. 1998, DeVries ym. 2003, Müller & Schrader 2003, Schlecht ym. 2004, Cangar ym. 2008, Cornou & Lundbye-Christensen 2008, Nadimi ym. 2008, O’Driscoll ym. 2008), mutta useimmat tähän mennessä kehitellyt systeemit kykenevät mittaamaan kerrallaan ainoastaan yhtä tai korkeintaan muutamaa käyttäytymismuotoa. Käytännön eläintuotannossa karjakokojen kasvaessa on pakko turvautua yhä useammin eläintuotannon pitkälle menevään automatisointiin. Automaattinen käyttäytymisen mittaustapa voisi auttaa eläinten hyvinvoinnin ja terveyden seurannassa.

Kiihtyvyyssantureita on käytetty useissa kokeissa, joissa on pyritty seuraamaan ihmisten käyttäytymistä ja terveyttä (kts. Mathien ym. 2004 katsausartikkeli). Kiihtyvyyssanturien käyttö eläintutkimuksissa on ollut huomattavasti vähäisempää (kts. kuitenkin esim. Watanabe ym. 2005, Scheibe & Gromann, 2006, Cornou & Lundbye-Christensen 2008).

Tutkimuksemme tavoitteena oli kehittää ja testata menetelmä, jolla voitaisiin mitata useita lypsylehmien käyttäytymismuotoja samanaikaisesti ja automaattisesti. Keräsimme tietoa lehmien liikkeistä kolmiulotteisella kiihtyvyyssanturilla ja mallinsimme aineiston moniluokkaisella tukivektorikoneluokittelijalla.

Aineisto ja menetelmät

Tutkimus tehtiin Ylä-Savon ammattiopiston Peltosalmen navetassa kesä-elokuussa 2007. Tutkimuksessa käytettiin kolmiulotteista kiihtyvyyssanturia (ADXL330, Analog Devices Inc., USA, mittaustulos ± 3 g), joka kiinnitettiin 30 lypsylehmän kaulapannan niskapuolelle (kts. tarkempi kuvaus järjestelmästä Järvinen ym. tässä julkaisussa). Anturi mittasi lehmien liikkeistä aiheutuvaa kiihtyvyyttä 10 Hz taajuudella. Lehmät saivat liikkua mittausten aikana vapaasti makuuparsipihatossa.

Kiihtyvyyssarvojen tulkitsemista ja luokitteluja varten lehmien käyttäytymistoiminnoista tehtiin havaintoja suoraan navetassa sekä videolta. Kustakin käyttäytymistoiminnosta kirjattiin sen alkamis- ja loppumisaika sekunnin tarkkuudella. Analysoitavia käyttäytymistoimintoja olivat seisominen paikoillaan (kerättyjen havaintojen lukumäärä 1356; havainnoitujen lehmien lukumäärä 30), makaaminen märehimättä (1150; 30), makuulla märehiminen (1411; 30), säilörehun syöminen (1017; 30), käveleminen normaalisti (568; 6), ontuminen (571; 9), makuulle laskeutuminen (63; 18) ja ylös nouseminen (101; 18). Kävelemisen luokittelemiseksi normaaliksi tai ontumiseksi lehmille tehtiin ontumisen arviointi Sprecherin ym. (1997) kuvailemalla 1–5 asteikolla kolme kertaa kuukauden välein tutkimuksen aikana. Normaalista kävelemistä vastasi asteikon arvo 1 (viisi lehmää / kuukausi) ja ontumisen mallinnukseen valittiin asteikon arvo 3 (5–8 lehmää / kuukausi).

Käyttäytymishavaintojen kanssa samanaikaisesti kerättyistä kiihtyvyyssmittauksista laskettiin 28 piirrettä (keskiarvo, keskihajonta, vinous, huipukkuus, maksimiarvo, minimiarvo ja energia kullekin kiihtyvyyssanturin kolmelle akselille; akselien kiihtyvyyssarvojen väliset korrelaatiot ja vektorin pituus) käyttäen laskennassa 10 sekunnin aikaikkunaa (kts. tarkemmin Martiskainen ym. 2009). Piirrevektorien saamat arvot skaalattiin nollan ja yhden välille.

Aineiston luokittelemiseen käytettiin tukivektorikonetta (*Support vector machine*, SVM), joka on 1990-luvulla kehitetty tilastollisen koneoppimisen teoriaan perustuva lineaarinen luokittelija (Vapnik, 1995, 1998). Luokittelumalli muodostettiin yhdistämällä kahdeksan kaksiluokkaista luokittelijaa (kts. tarkemmin Martiskainen ym. 2009). Luokittelijan opetuksessa käytettiin 70 % ja testauksessa 30 % aineistosta (yhteensä 11693 riviä). Mallinnus tehtiin Matlab R2007b -ohjelmistolla (The MathWorks Inc., Natick, USA).

Luokittelumallien hyvyttä arvioitiin ulkoisen (*accuracy*) ja sisäisen tarkkuuden (*precision*) (Kohavi & Provost 1998) sekä kappa-arvon (Cohen 1960) avulla. Ulkoinen tarkkuus kertoo, kuinka suuren osan tapauksista malli kokonaisuudessaan luokittelee oikein, eli esimerkiksi seisomista mallinnettaessa luokittelee havaitun seisomisen (positiivinen tapaus) seisomiseksi ja muut havainnot kuin seisomisen (negatiiviset tapaukset) ”muuksi käyttäytymiseksi”. Sisäinen tarkkuus kertoo, kuinka suuren osuuden esimerkiksi havaituista seisomistapauksista malli myös luokittelee seisomiseksi.

Kappa-arvon perusteella arvioitiin luokittelun satunnaisuutta. Kapan arvo 0 vastaa täysin satunnaista luokittelua. Mitä lähempänä kapan arvo on lukua 1, sitä vähemmän luokittelussa on satunnaisuutta.

Tulokset ja tulosten tarkastelu

Luokittelumallien ulkoinen tarkkuus oli kaikilla malleilla hyvä (taulukko 1). Tunnuksluvun tulkitsemisen tekee kuitenkin hankalaksi se, että positiivisia tapauksia oli aineistossa varsin vähän negatiivisiin tapauksiin verrattuna. Vaikka malli olisi luokitellut esimerkiksi kaikki seisomishavainnot ”muuksi käyttäytymiseksi”, ulkoinen tarkkuus olisi edelleen erittäin hyvä (esim. Kubat ym. 1998). Siksi sisäinen tarkkuus, eli kuinka suuren osan positiivisista tapauksista malli luokitteli oikein, on tulosten tarkastelun kannalta parempi tunnusluku. Luokittelumalli tunnisti käyttäytymistoiminnoista parhaiten makuulla märehtimisen, makaamisen, säilörehun syömisen ja normaalisti kävelemisen. Hiukan heikommin tunnistettiin ontuminen ja seisominen. Nämä kaksi käyttäytymismuotoa ovat voineet sekoittua ”kiihtyvyysoireiltaan” vastaavien käyttäytymismuotojen, eli tässä tapauksessa normaalin kävelemisen ja paikoillaan makaamisen kanssa. Makaaminen ja seisominen olisi helppoa erottaa toisistaan pelkästään kiihtyvyysoireiltaan asennon perusteella, jos anturi sijaitisi eläimen jalassa (vrt. esim. Yoda ym. 2001). Toisaalta jalassa olevalla anturilla ei pystyttäisi mittamaan lainkaan esimerkiksi syömistä tai märehtimistä, jotka onnistuttiin nyt luokittelemaan melko hyvin. Luokittelun kannalta optimaalisinta olisi, että lehmällä olisi useampia antureita eri kohdissa kehoa. Käytännön sovellutusten kannalta useat anturit eivät kuitenkaan ole käytännöllisiä.

Makuulle laskeutumisen ja ylös nousemisen tunnistaminen aineistosta ei onnistunut mallintamiseen käytettyjen havaintojen vähäisen lukumäärän vuoksi (taulukko 1). Kyseisistä käyttäytymismuodoista tehdyistä havainnoista valikoitui luokitteluun vain pieni osa mallinnuksessa käytetyn 10 sekunnin aikaikkunan vuoksi, sillä suurin osa käyttäytymishavainnoista oli kestoaltaan tätä lyhyempiä. Voi olla, että aikaikkuna on määriteltävä erikseen jokaiselle mallinnettavalle käyttäytymismuodolle parhaiden luokittelutulosten saavuttamiseksi.

Taulukko 1. SVM-luokittelijan hyvyttä kuvaavat tunnusluvut ulkoinen ja sisäinen tarkkuus sekä kappa-arvo (ka \pm S.D.).

Käyttäytymismuoto	Ulkoinen tarkkuus ¹	Sisäinen tarkkuus ²	Kappa ³
Seisominen	0,87 \pm 0,01	0,65 \pm 0,02	
Makaaminen	0,84 \pm 0,01	0,83 \pm 0,02	
Makuulla märehtiminen	0,92 \pm 0,01	0,86 \pm 0,02	
Säilörehun syöminen	0,96 \pm 0,01	0,81 \pm 0,03	
Normaali käveleminen	0,99 \pm 0,00	0,79 \pm 0,07	
Ontuminen	0,98 \pm 0,00	0,66 \pm 0,07	
Makuulle laskeutuminen	1,00 \pm 0,00	0,00 \pm 0,00	
Ylös nouseminen	1,00 \pm 0,00	0,29 \pm 0,32	
Koko luokittelumalli		0,78 \pm 0,01	0,69 \pm 0,02

¹ Oikein luokiteltujen (positiivinen tai negatiivinen) tapausten määrä.

² Osuus positiivisista tapauksista, jotka luokiteltiin positiiviseksi.

³ Luokittelun satunnaisuutta kuvaava tunnusluku.

Koko luokittelumallin sisäinen tarkkuus oli 0,78 (taulukko 1), joka on varsin hyvä tulos biologista alkuperää olevaa aineistoa mallinnettaessa. Kapan arvo 0,69 tarkoittaa, että malli luokittelee käyttäytymiset selkeästi paremmin, kuin voitaisiin odottaa tapahtuvan pelkän sattuman tuloksena (Sim & Wright 2005).

Johtopäätökset

Käyttämämme luokittelumalli ei näytä sellaisenaan sopivan lyhytkestoisten käyttäytymistoimintojen mallintamiseen. Käytetyt luokittelumallit vaativatkin vielä kehittämistä luotettavampien tulosten saavuttamiseksi. Kiihtyvyysoireiltaan hyödyntäminen lypsylehmiä käyttäytymisen seurannassa on tulostemme perusteella kuitenkin mahdollista.

Kirjallisuus

- Abe, S.** 2005. Support vector machines for pattern classification. Springer-Verlag, London.
- Cangar, Ö., Leroy, T., Guarino, M., Vranken, E., Fallon, R., Lenehan, J., Mee, J. & Berckmans, D.** 2008. Automatic real-time monitoring of locomotion and posture behaviour of pregnant cows prior to calving using online image analysis. *Comput. Electron. Agr.* 64: 53-60.
- Cornou, C. & Lundbye-Christensen, S.** 2008. Classifying sows' activity types from acceleration patterns: an application of the multi-process Kalman filter. *Appl. Anim. Behav. Sci.* 111: 262-273.
- DeVries, T.J., von Keyserlingk, M.A.G., Weary, D.M. & Beauchemin, K.A.** 2003. Technical note: validation of a system for monitoring feeding behaviour of dairy cows. *J. Dairy Sci.* 86: 3571-3574.
- Haley, D.B., de Passillé, A.M. & Rushen, J.** 2001. Assessing cow comfort: effects of two floor types and two tie stall designs on the behaviour of lactating dairy cows. *Appl. Anim. Behav. Sci.* 71: 105-117.
- Krohn, C.C. & Munksgaard, L.** 1993. Behaviour of dairy cows kept in extensive (loose housing/pasture) or intensive (tie stall) environments. II. Lying and lying-down behaviour. *Appl. Anim. Behav. Sci.* 37: 1-16.
- Kubat, M., Holte, R.C. & Matwin, S.** 1998. Machine learning for the detection of oil spills in satellite radar images. *Mach. Learn.* 30: 195-215.
- Martiskainen, P., Järvinen, M., Skön, J.-P., Tiirikainen, J., Kolehmainen, M. & Mononen, J.** 2009. Cow behaviour pattern recognition using a three-dimensional accelerometer and support vector machines. *Appl. Anim. Behav. Sci.* 119: 32-38.
- Mathie, M.J., Coster, A.C.F., Lovell, N.H. & Geller, B.G.** 2004. Accelerometry: providing an integrated, practical method for long-term, ambulatory monitoring of human movement. *Physiol. Meas.* 25: R1-R20.
- Müller, R. & Schrader, L.** 2003. A new method to measure behavioural activity levels in dairy cows. *Appl. Anim. Behav. Sci.* 83: 247-258.
- Nadimi, E.S., Søgaaard, H.T. & Bak, T.** 2008. ZigBee-based wireless sensor networks for classifying the behaviour of a herd of animals using classification trees. *Biosyst. Eng.* 100: 167-176.
- O'Driscoll, K., Boyle, L. & Hanlon, A.** 2008. A brief note on the validation of a system for recording lying behaviour in dairy cows. *Appl. Anim. Behav. Sci.* 111: 195-200.
- Scheibe, K.M. & Gromann, C.** 2006. Application testing of a new three-dimensional acceleration measuring system with wireless data transfer (WAS) for behavior analysis. *Behav. Res. Methods* 38: 427-433.
- Scheibe, K.M., Schleusner, T., Berger, A., Eichhorn, K., Langbein, J., Dal Zotto, L. & Streich, W.J.** 1998. ETHOSYS (R) – new system for recording and analysis of behaviour of free-ranging domestic animals and wildlife. *Appl. Anim. Behav. Sci.* 55: 195-211.
- Schlecht, E., Hülsebusch, C., Mahler, F. & Becker, K.** 2004. The use of differentially corrected global positioning system to monitor activities of cattle at pasture. *Appl. Anim. Behav. Sci.* 85: 185-202.
- Sim, J. & Wright, C.C.** 2005. The kappa statistic in reliability studies: Use, interpretation, and sample size requirements. *Phys. Ther.* 85: 257-268.
- Sprecher, D.J., Hostetler, D.E. & Kaneene, J.B.** 1997. A lameness scoring system that uses posture and gait to predict dairy cattle reproductive performance. *Theriogenology* 47: 1179-1187.
- Vapnik, V.** 1995. *The nature of statistical learning theory.* Springer-Verlag, New York.
- Vapnik, V.** 1998. *Statistical learning theory.* John Wiley and Sons, Inc., New York.
- Watanabe, S., Izawa, M., Kato, A., Ropert-Coudert, Y. & Naito, Y.** 2005. A new technique for monitoring the detailed behaviour of terrestrial animals: a case study with the domestic cat. *Appl. Anim. Behav. Sci.* 94: 117-131.
- Yoda, K., Naito, Y., Sato, K., Takahashi, A., Nishikawa, J., Ropert-Coudert, Y., Kurita, M. & Le Maho, Y.** 2001. A new technique for monitoring the behaviour of free-ranging Adélie penguins. *J. Exp. Biol.* 204: 685-690.