

Otto Eerola

NIELEMISEN LUOKITUS KÄYTTÄEN KONEOPPIMISTA JA ÄLYKAULURIA

Informaatioteknologian ja viestinnän tiedekunta
Kandidaatintyö
Helmikuu 2023

TIIVISTELMÄ

Otto Eerola: Nielemisen luokitus käyttäen koneoppimista ja älykauluria
Kandidaatintyö, 17 sivua, 2 liitesivua
Tampereen yliopisto
Sähkötekniikan koulutusohjelma
Pääaine: Signaalinkäsittely ja koneoppiminen
Helmikuu 2023

Nielemishäiriöiden lääketieteellisessä arvioinnissa on tärkeää tunnistaa potilaan kyky nielemiseen. Perinteisesti tämä tehdään alan ammattilaisten silmämääräisellä seuranta- ja merkintäprosessilla yleensä videolta. Olisi kuitenkin ajan ja resurssikäytön kannalta hyödyllistä, jos nielemiset voitaisiin tunnistaa automaattisesti esimerkiksi sopivaa älyvaatetta tai muuta mittalaitetta käyttäen. Tämä mahdollistaisi tutkittavan henkilön seurannan kliinisten olosuhteiden ulkopuolella.

Tässä työssä tutkittiin nielemisreaktion luokittelun menetelmiä koneoppimisen keinoin. Luokitusta tehtiin 17 tutkimushenkilöstä älykaurilla kerätystä ja lääketieteen ammattilaisen todentamalla datalla. Tarkoituksena oli löytää maksimaalisen tarkkuuden tuottava esikäsitely-, piirrevalinta- ja luokitusketju. Menetelmäketjua rajoitti tarve toteuttaa se suhteellisen pienen tutkimusdataotannan ja konetehon asettamisessa puitteissa.

Menetelmät tämän ketjun eri vaiheisiin valittiin nojaten aikaisempiin koneoppimis- ja nielemishäiriötutkimuksiin. Menetelmäyhdistelmiä ja niiden tuottamia lopputuloksia verrattiin koneoppimisesta tuttuihin tarkkuusmittareihin. Havaintoja kirjattiin myös älykaurin anturikokonaisuuden tutkinnan kannalta. Kokonaistarkkuuden lisäksi pyrittiin päättämään anturien ja anturiyhdistelmien relevanssia luokittelussa ja tarkkuudessa.

Valituilla menetelmillä saavutettiin 82,22 % tarkkuus, jota voidaan pitää merkittävänä tuloksena varsinkin huomioon ottaen mittalaitteiston prototyyppinen aste sekä mittausdatan suhteellinen niukkuus ja siihen liittyvät epävarmuustekijät. Tutkimuksella saavutettiin hyvä lähtöasetelma tulevaisuuden kehitystyöhön signaalipohjaisen nielemisreaktion automaattisen tunnistuksen osalta.

Avainsanat: koneoppiminen, luokitus, nielemishäiriö, nielemisen tunnistus, älykauri

Tämän julkaisun alkuperäisyys on tarkastettu Turnitin OriginalityCheck -ohjelmalla.

ABSTRACT

OTTO EEROLA: Classification of swallowing using a neck gaiter with augmented sensors

Bachelor's Thesis, 17 pages, 2 attachment pages

Tampere University

Bachelor's Programme in Computing and Electrical Engineering

February 2024

In the medical evaluation of swallowing disorders, it is important to identify the patient's ability to swallow. Traditionally, this is done with the visual monitoring and marking process of professionals in the field, usually from video. However, it would be useful in terms of time and resource use if swallowing could be recognized automatically using, for example, a suitable smart garment or other measuring device. This would make it possible to monitor the subject outside of clinical conditions

In this work, the methods of classifying the swallowing reaction were investigated using machine learning. Data was collected from 17 research subjects with the smart collar and verified by a medical professional. The purpose was to find a pre-processing, feature selection and classification chain that produces maximum accuracy. The method chain was limited by the need to implement it within the framework set by a relatively small research dataset and computational power.

The methods for the different stages of the chain were chosen based on previous machine learning and swallowing disorder studies. Method combinations and the results they produced were compared to accuracy metrics known from machine learning. Observations were also recorded in terms of the investigation of the sensor relevancy of the smart collar. In addition to the overall accuracy, an effort was made to conclude the relevance of sensors and sensor combinations in classification and accuracy.

With the chosen methods, an accuracy of 82.22 % was achieved, which can be considered a significant result, especially considering the prototype level of the measurement equipment and the relative scarcity of measurement data and the associated uncertainty factors. The study achieved a good starting point for future development work regarding the automatic recognition of the signal-based swallowing reaction.

Keywords: machine learning, classification, dysphagia, detection of swallowing, neck gaiter with augmented sensors

The originality of this thesis has been checked using the Turnitin OriginalityCheck service.

SISÄLLYSLUETTELO

1. JOHDANTO	1
2. TAUSTA.....	2
2.1 Nielemishäiriö	2
2.2 Älykauluri	2
2.3 Koneoppiminen	3
2.3.1 Lineaarinen regressio	4
2.3.2 Tukivektorikone.....	4
2.4 Koneoppiminen nielemisen tunnistuksessa.....	8
3. MENETELMÄT	9
3.1 Data	9
3.2 Esikäsittely	9
3.2.1 Keskiarvon poisto.....	10
3.2.2 Ylipäästösuodatin.....	10
3.3 Piirteiden valinta.....	11
3.3.1 Aikatason piirteet	11
3.3.2 Taajuustason piirteet.....	12
3.3.3 Pääkomponenttianalyysi	12
3.4 Käytetyt luokittimet.....	12
3.4.1 Lineaarinen regressio	12
3.4.2 Tukivektorikone.....	12
4. KOKEET	13
4.1 Mallin optimointi	13
4.2 Esikäsittelyn vaikutus	13
4.3 Piirrevalinnan merkitys	13
4.4 Sensorivalinta	13
4.5 Satunnaisvalinta.....	14
4.6 Mittarit.....	14
5. TULOKSET	15
6. YHTEENVETO.....	17
LÄHTEET	18

LYHENTEET JA MERKINNÄT

C	Regularisaatioparametri
C-SVM	Soft Margin Support Vector Machine
FFT	Fast Fourier Transform
FIR	Finite Impulse Response
PCA	Principal Component Analysis
LOSO	Leave One Subject Out
SVM	Support Vector Machine
ξ	Joustotermi

1. JOHDANTO

Nielemisvaikeus eli dysfagia on yleinen vaiva maailmanlaajuisesti. Joka kuudes aikuinen ilmoittaa kärsivänsä nielemisvaikeuksista[1]. Aiheen tutkimustyö pohjaa vahvasti kliinisissä olosuhteissa kuvattuihin videoihin, joista nielureaktiot pitää lääketieteen ammattilaisten todentaa. Puettava mittalaite kuten älykauluri mahdollistaisi nielureaktion seurannan esimerkiksi kotona. Tämä vapauttaisi resursseja ja helpottaisi tutkimusta.

Tämän työn tarkoituksena oli tutkia nielureaktion luokitusta koneoppimisen keinoin käyttäen älykaulurilla[2] kerättyä mittadataa 17 tutkimushenkilöltä. Työ tähtäsi mahdollisimman tarkkaan nielureaktion luokitukseen kaulan alueen liikkeen perusteella. Parhaan tarkkuuden toteuttamiseksi kokeiltiin erilaisia kolmivaiheisia metodiketjuja. Metodiketjujen vaiheet jakaantuivat esikäsittelyyn, piirrevalintaan sekä luokitukseen.

Kaulalta tapahtuvaa mittausta ja nielemisen luokituksia on tutkittu aiemminkin koneoppimisen keinoin [12][13][14][15], mutta käyttäen erilaista anturikokoonpanoa kuin työn älykaulurissa olevat kolmesuuntaiset kulmanopeus- ja kiihtyvyyssanturit. Myös menetelmät kuten neuroverkkojen käyttö [24] ovat usein vaatineet suurempaa tutkimusdataa ja enemmän laskentatehoa kuin työssä käytetyt. Aiheessa olisi ollut tutkittavaa paljon enemmänkin, kuten datan graafisen esityksen, väärin tuloksien virheanalyysin ja reaaliaikaisen havaitsemisen piirissä, mutta aihe rajattiin pääasiallisesti koskemaan nielureaktion tunnistusta tutkien siihen liittyen esikäsittelyn ja piirrevalinnan merkitystä.


Työ implementoitiin Matlab-ohjelmistolla hyödyntäen "Statistics and machine learning toolbox"- ja "Signal processing toolbox"-kirjastoja. Luokittimiksi valittiin logistinen regressio malli sekä tukivektorikone.

2. TAUSTA

Koneoppiminen on edelleen kasvava trendi, ja nielemishäiriöntutkinnassa sitä on hyödynnetty yli vuosikymmenen [12][14]. Koneoppimisella voidaan vapauttaa tutkintaresursseja muuhun käyttöön kuin esimerkiksi asioiden silmämääräiseen todentamiseen sekä mahdollistaa kliinisten olosuhteiden ulkopuolella tapahtuvat mittaukset ja tutkimukset. Mittauslaitteistojen, kuten mikrokontrollerien ja anturien, jatkuva kehitys mahdollistaa vanhempienkin koneoppimismallien käyttämisen tunnistustehtävissä. Niiden avulla voidaan saavuttaa luotettavia tuloksia, jotka voivat olla hyödynnettävissä myös lääketieteen teknologiassa. Tässä kappaleessa esitellään nielemishäiriötä ilmiönä, sen mittaukseen käytettyä älykauluria ja sen mittadataan soveltuvia koneoppimismenetelmiä.

2.1 Nielemishäiriö

Nielemisen jaetaan neljään vaiheeseen; pre-oraaliseen eli valmistelemaan vaiheeseen, sekä oraaliseen, faryngeaaliseen ja esofageaaliseen vaiheeseen.



Kuva 2.1 Nielemisen vaiheet (kuva kopioitu lähteestä [3])


Dysfagia eli nielemishäiriö on yhden tai useamman vaiheen ongelman tuottama nielemisen vaikeus, jolloin ruuan tai juoman kuljettaminen suusta ruokatorveen on vaikeutunut tai ei onnistu lainkaan [3].

Koska nielureaktio on yhdistelmä kurkunpään ja suun alueen lihaksistojen erilaisia toimintavaiheita (kuva 2.1), on perusteltua olettaa, että nämä lihaksien normaalit, dysfagiassa epänormaalit tai pahimmillaan puuttuvat liikkeet ovat havaittavissa, sekä tulkittavissa mittauksista myös kaulan ulkopinnalta mitattavassa liikkeessä.

2.2 Älykauluri

Tässä tutkimuksessa käytettiin aiemmassa tutkimuksessa esitellyllä älykaulurilla [2] kerättyä tutkimusaineistoa. Älykauluri käyttää kahdeksaa pientä kulmanopeus- ja kiihtyvyyssanturia (21 mm × 15 mm × 4 mm), joista datan keräysvaiheessa oli älykauluriin kytkettyinä seitsemän. Kahdeksas anturi oli referenssitarkoituksena irti kaulurista. Jokainen kahdeksasta sensorikonaisuudesta oli MPU-6050 MEMS-IMU komponentti, joka

sisältää molemmat anturityypit kolmesuuntaisena. Jokainen anturi on kytketty LPC1768 mikrokontrolleriin ja kiinnitetty velcron-materiaalista tehtyyn kaulan ympärille kiinnitettävään kauluriin



Kuva 2.2 Älykaulurin sensorikokoonpano (kuva kopioitu lähteestä[2])

Mainitusta tutkimuksesta poiketen antureiden sijaintia oli tämän työn datan keräämisen suhteen vaihdettu hieman. Sijainnit olivat leuan alla, kieliluun vasemmalla puolella, kieliluun oikealla puolella, kurkunpäässä, kaulalla alavasemmalla, kaulalla alaoikealla ja niskassa.

2.3 Koneoppiminen

Koneoppimismallit jakaantuvat kolmeen perustyyppiin, joita ovat ohjattu-, vahvistus- ja ohjaamaton oppiminen [4]. Tähän työhön soveltuvat ja siinä käytettävät kuuluvat ensimmäiseen eli ohjattuun oppimiseen. Tämä valinta johtuu käytössä olevan aineiston luonteesta, sillä data on ennalta mitattua, ja sen todennetut tutkimuksen kannalta kiinnostavat luokat ovat jokaisella ajanhetkellä tiedossa mallin opettamista varten.

Ohjattu oppiminen on tekoälyyn liittyvä koneoppimisen menetelmä, jossa opetusaineiston syötteiden ja valmiiksi todennettujen tuloksien avulla muodostetaan funktio. Tätä kutsutaan mallin opettamiseksi. Funktio mahdollistaa joko olemassa olevien tai uusien näytteiden luokittelun ennalta annettuihin luokkiin näytteistä laskettujen piirteiden perusteella, jota kutsutaan luokitteluksi [4]. Toinen vaihtoehto on opettaa koneelle funktio, joka piirteistää syötteen jatkuva-arvoiseksi luvuksi tai vektoriksi, jota kutsutaan regressioksi. Regressiota voidaan käyttää myös luokitteluun, jos regression ulostulo muunnetaan luokkatiedoksi esimerkiksi ennalta määrättyjen raja-arvojen perusteella.

Tässä työssä käytettäviä malleja on kaksi. Lineaarinen regressio valittiin yksinkertaiseksi pohjamalliksi kirjallisuutta jäljitellen. Empiiristen tulosten pohjalta toiseksi vaihtoehdoksi valittiin tukivektorikone sen alustavissa kokeissa hyväksi osoittautuneiden tulosten perusteella.

2.3.1 Lineaarinen regressio

Lineaarinen regressio oli historiallisesti ensimmäinen regressioanalyysin tyyppi, jota tutkittiin tarkasti ja jota käytettiin laajasti käytännön sovelluksissa[5]. Koneoppimisen alalla tilastollisen luokituksen tavoitteena on tunnistaa objektin ominaisuuksien avulla, mihin luokkaan (tai ryhmään) se kuuluu. Lineaarinen luokitin saavuttaa tämän, tekemällä luokitus päätöksen ominaisuuksien lineaarisen yhdistelmän arvon perusteella. Objektin ominaisuudet tunnetaan myös ominaisuusarvoina tai piirteinä, ja ne esitetään tyypillisesti koneelle vektorissa, jota kutsutaan piirrevektoriksi.

Vaikka lineaariset luokittimet saattavat epäonnistua ei-separoituvien luokkien jaottelussa, on osoitettu luokittimien myös toimivan hyvin käytännön ongelmissa, kuten asiakirjojen luokittelussa, ja yleisemmin usean muuttujan (piirteiden) ongelmissa. Tällaisissa tapauksissa, kuten asiakirjan luokitteluongelmassa, on osoitettu lineaarisen luokittimen tarkkuustason olevan kilpailukykyinen ei-lineaarisiin luokittimiin, mutta niiden harjoittaminen ja käyttö vievät vähemmän aikaa kuin monimutkaisemmilla luokittimilla [6]. Lineaarisen regression matemaattinen malli soveltuu hyvin ratkaistavaksi seuraavalla matriisialgebramallilla [7]:

$$Y = XB + E, \quad (2.1)$$

jossa Y edustaa pystyvektoria, joka sisältää valmiiksi tunnetut luokitukset jokaiselle näytteelle, joita käytetään mallin opettamiseen. X on piirrevalintavaiheessa luotu piirrematriisi. Binäärisen luokituksen tapauksessa B on tarkoitus ratkaista niin, että matriisikertolaskun tuloksena saamme luokittelun tuloksen -1 tai 1 uuden datan luokitteluvaiheessa soveltamalla matriisikertolaskua uusiin syötteisiin. Biastermien E -matriisin voimme implementoinnissa hylätä, jolloin saamme yhtälön muotoon

$$Y = XB. \quad (2.2)$$

Kuten lineaarialgebrasta tiedetään, nyt yhtälö on muokattavissa muotoon


$$B = X^{-1}Y. \quad (2.3)$$

jossa X^{-1} on X -matriisin käänteismatriisi ja siten ratkaisu lineaariluokittimen optimointiongelmaan.


2.3.2 Tukivektorikone

Koneoppimisessa tukivektorikoneet (eng. "support vector machine", eli SVM), myös tukivektoriverkot [8], ovat ohjattuja koneoppimismalleja ja niihin liittyviä oppimisalgoritmeja, jotka analysoivat dataa luokittelua ja regressioanalyysiä varten. SVM kehitettiin alun perin binääriluokittimeksi [8] ja sellaisena sitä myös tässä työssä hyödynnetään.

Alkuperäisen konseptin julkaisivat Vladimir N. Vapnik ja Aleksei Ya. Chervonenkis vuonna 1963. Se toteutti käsitteellisesti seuraavan idean: syötevektorit kuvataan epälineaaraisesti erittäin korkean ulottuvuuden piirreavaruuteen [9]. Tässä piirreavaruudessa rakennetaan lineaarinen päätöspinta näytejoukkojen väliin niin, että päätöspinnan kanssa yhdensuuntaiset marginaalipinnat ovat mahdollisimman kaukana toisistaan. Optimointi pyritään toteuttamaan siten, ettei yksikään näyte jää päätöspinnan ja marginaalipinnan väliselle tasolle eli marginaaliin. Tätä kutsutaan optimimarginaaliluokittimeksi (engl. hard-margin classifier). Näytejoukon pisteitä, joiden läpi kulkee marginaalipinta, kutsutaan tukivektoreiksi. Syötevektorien kuvausta korkeaan piirreavaruuteen ja optimimarginaaliluokittinta havainnollistetaan kuvissa 2.3 ja 2.4.



Kuva 2.3 Syötevektorien projektiio pիրreavaruuteen (kuva lähteestä[18])



Kuva 2.4 Optimimarginaalinen lineaarinen luokitin. Kuvassa päätöspinta punaisella, katkoviivalla merkityn marginaalipinnan päälle asettuvat näytteet ovat tukivektoreita (kuva lähteestä[19])

Optimimarginaalisen hypertason määrittämiseksi matemaattisesti olkoon opetusjoukko

$$(y_1, x_1), \dots, (y_l, x_l) \quad y_i \in \{-1, 1\}, \quad (2.4)$$

jonka sanotaan olevan lineaarisesti separoituva, jos on olemassa vektori w ja skalaari b siten että kaikille opetusjoukon jäsenille pätee epäyhtälöt

$$w \cdot x_i + b \geq 1 \text{ kun } y_1 = 1, \quad (2.5)$$

$$w \cdot x_i + b \leq -1 \text{ kun } y_1 = -1. \quad (2.6)$$

Epäyhtälöt sievenevät muotoon

$$y_i(w \cdot x_i + b) \geq 1, i = 1, \dots, l. \quad (2.7)$$

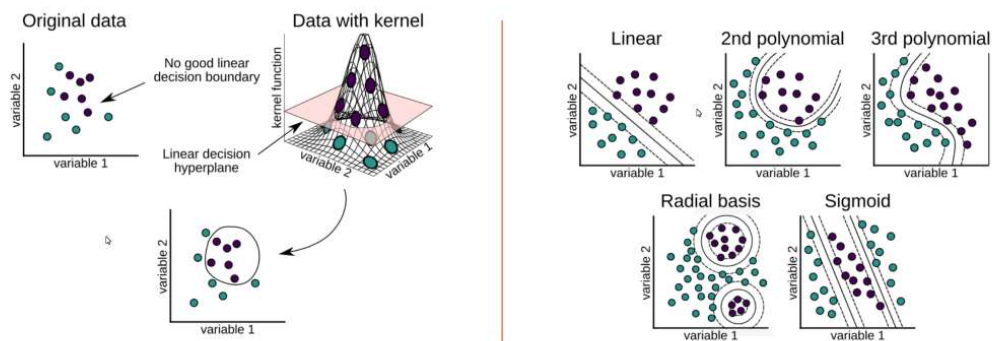
Optimimarginaalinen hypertaso

$$w_0 \cdot x + b_0 = 0 \quad (2.8)$$

on se, joka erottaa opetusjoukot suurimmalla marginaalilla kuten kuvassa 2.4. Tukivektorit ovat ne x_i joille

$$y_i(w \cdot x_i + b) = 1. \quad (2.9)$$

Vuonna 1992 Boser, Guyon ja Vapnik esittivät tavan luoda epälineaarisia luokittimia soveltamalla ns. Kernel-temppua (engl. kernel trick) optimimarginaalin hypertasoihin [10], joka sittemmin on vakiintunut olennaiseksi osaksi tukivektorikoneiden käyttöä



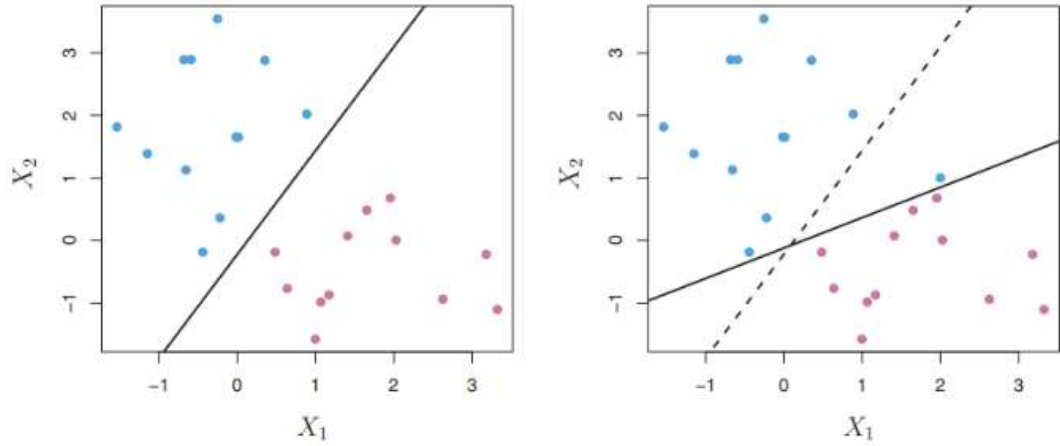
Adding one extra dimension, here stretching into 3D, makes data points linearly separable.

Kernel functions, examples. Solid line = decision boundary (projected back onto the original feature space). Dashed lines = margin.


Kuva 2.5 Kernel-temppu lineaarisesti separoitumattomille näytejoukoille (kuva lähteestä [20])

Optimimarginaalisessa toteutuksessa on kuitenkin ongelmia. Ensinnäkin toteutus soveltuu vain separoituville näytejoukoille ja ei ole siksi mielekäs reaali maailman luokittelutehtävissä, joissa opetusjoukon ulkopuolisten näytepisteiden täydellinen erottelu on usein mahdotonta. Ja joskin näytejoukko on separoituva, saattaa marginaali ajautua erittäin kapeaksi. Tällöin optimimarginaalin ehdoton rajaus tekee sen hyvin herkäksi massasta poikkeaville (eng. "outlier") havainnoille. Marginaalin kapenemisongelma osoitetaan graafisesti kuvassa 2.6.

Cortes ja Vapnik ehdottivatkin joustavan marginaalin (engl. soft margin) luokittinta 1993, jota käytetään yleisesti nykypäivän koneoppimisen ohjelmistopaketeissa. Tutkimus julkaistiin vuonna 1995 [8]. Joustavan marginaalin tukivektorikone (C-SVM) on optimaalimarginaaliluokittimen yleistys ei-separoituville näytejoukoille, joita lähes kaikki mittausdatat kohinoineen ja mittavirheineen ovat. Käytännön vuoksi on tarve määrittellä opetusnäytejoukon pisteitä joskus myös väärin. Kun tehdään kompromisseja päätöspintojen vektorirajoissa suhteessa yksittäisiin opetusaineiston mittapisteisiin, saavutetaan usein luokitustarkkuuden kannalta kokonaisuudeltaan parempi lopputulos uusilla havaittavilla mitta pisteillä. Joustavan marginaalin edut on havaittavissa kuvasta 2.7.



Kuva 2.6 Oikea kuva osoittaa marginaalin kapenemisongelman. Kun vasemman kuvan luokitin, saa siniseen luokkaan yhden reunatapauksen lisää, muuttuu luokittimen päätöstaso radikaalisti. Katkoviiva on vanha päätöstaso. (kuva lähteestä[21])



Kuva 2.7 Joustava marginaali oikealla ei alisovita merkittyjen poikkeamien vuoksi (kuva lähteestä[22])

C-SVM määrittellään erottamaan näytejoukot mahdollisimman pienellä virhemäärällä. Tämä toteutetaan regularisaatioparametrilla C , joka määrittää marginaalin leveyttä, ja joustotermillä ξ . Optimimarginaalin rajoittavaa tekijää muutetaan seuraavasti

$$y_i(w \cdot x_i + b) \geq 1 - \xi_i, \quad i = 1, \dots, l, \quad (2.10)$$

$$\xi_i \geq 0, \quad i = 1, \dots, l. \quad (2.11)$$

Optimointiongelma, jossa F on käytössä oleva päätösfunktio, minimoi virheluokituksien määrän mutta maksimoi marginaalin on muotoa

$$\text{minimoi } \frac{1}{2} w^2 + CF(\sum \xi_j), \quad (2.12)$$

suhteessa rajoitteisiin 2.10 ja 2.11.[8]

2.4 Koneoppiminen nielemisen tunnistuksessa

Nielureaktion luokittelua käyttäen koneoppimista on tutkittu useasti aiemminkin, mutta käyttäen hieman erilaisia anturikokoonpanoja, kuin 2.2 kappaleessa mainitussa älykauritutkimuksessa [2], kuten pelkällä kaksiulotteisella kiihtyvyyssanturilla toteutettu [12] kolmiulotteisella kiihtyvyyssanturilla useaa luokkaa silmällä pitäen [13], mikrofoneja käyttäen [14], kiihtyvyy- ja PPG-anturia hyödyntäen [15] ja näistä pystyi päättämään hyväksi todettuja tapoja tässä työssä käytettävään esikäsittely-, piirrevalinta- ja luokitin-ketjuun.


Kuitenkin aiemmista tutkimuksista poiketen älykaururi olisi helpommin mobiilisoitavissa ja kehitettävissä tarkemmaksi anturien ja akkuteknologian kehityttyä spesifiin kahden luokan käyttötarkoitukseen. Vaihtoehto olisi myös käyttäjäystävällisempi lääketieteellisiin tutkimuksiin samalla mahdollistaen arkielämän toiminnan.

3. MENETELMÄT

Nielemisen automaattisen luokituksen menetelmäkehitystä lähestyttiin signaalikäsitteilyn ja koneoppimisen keinoin. Menetelmäkehityksen tavoitteena oli menetelmäketju, joka tuottaa parhaan luokitustarkkuuden. Menetelmäketju pitää sisällään raakadatan esikäsittelyn, jossa on tarkoitus poistaa epäoleellisia ominaisuuksia signaalista, kuten esimerkiksi kohinaa tai valumaa, ja toisaalta taas korostaa oleellisia luokitusta tukevia piirteitä.

Toinen vaihe ketjussa on piirteiden valinta. Piirteet ovat sitä signaalin sisältämää informaatiota, joka on kyseisen luokitus- tai tunnistusongelman kannalta keskeistä. Näin valittuja piirteitä eli tietyn tyyppistä signaali-informaatiota voidaan hyödyntää mallin opetuksessa, mallilla luokittelussa tai tunnistuksessa. Erilaisia piirteistyksiä voidaan luoda sekä aikatasossa että taajuustasossa.

Ketjun viimeisessä vaiheessa koneoppimisen malli optimoidaan ja opetetaan ensimmäisen ja toisen vaiheen jälkeen saadulla piirteistöillä luokittelemaan sille ennalta tuntematonta dataa. Menetelmäketju, jonka vaiheita työssä varioidaan, on kuvattu alla lohkokkaaviona (Kuva 3.1).



Kuva 3.1 Työn tutkimusprosessin lohkokkaavio

Vaikka koneoppimisen alueella on menetelmäketjun jokaiseen vaiheeseen monipuolisesti vaihtoehtoja, rajoittaa datan laatu yleensä menetelmien valintaa. Esikäsittelyn ja piirteiden valinta on erilainen mittasignaalin laadun mukaan. Luokittimen valintaa rajoittaa esimerkiksi käytössä olevan datan määrä. Työssä käytetyt ohjelmakoodit ovat ladattavissa osoitteessa <https://github.com/Xnotee/Smart-neck-gaunter-data-bruteforcer>.

3.1 Data

Aiemmassa tutkimuksessa (ei julkaistu) älykaurilla oli kerätty noin 17 minuuttia 17 vapaaehtoisen niepureaktioita kuten veden juomista. Seitsemästä anturista tallennettiin signaalitietoa 100 Hz näytteenottotaajuuksella. Koska jokaisessa anturikonaisuudessa oli kolmisuuntaiset kulmanopeus- ja kiihtyvyyssanturit, jokaista anturikonaisuutta kohden tuli kuusi mittasignaalia. Käsitteilyistä kaikkien signaalit täytettiin samaan mittaan NaN-arvoilla ja lopulta tensori oli muotoa 140 706 näytettä kutakin 42 anturisignaalia kohden ja kullekin 17 henkilölle, eli 140706x42x17. Koehenkilöiden määrän vuoksi datan rakenne oli hankala monia sovelluksia ajatellen: data oli samanaikaisesti näytemäärältään niukka koneoppimismallin opettamiseen, mutta myös korkeadimensionaalinen piirteiden ja kanavien osalta.


Datan vähyys tuo haasteita opetusmallin kykyyn yleistää jatkossa käytettäviin eli ennalta näkemättömiin luokitusdatoihin. Jos näiden ominaispiirteet eroavat opetusaineistosta, ei täydellisesti opetusdatan mukainen malli kykene tunnistamaan erilaisia ominaisuuksia omaavia luokituksessa olevia dataryhmiä.

3.2 Esikäsittely

Datan esikäsittely tarkoittaa joko datan manipulaatiota tai sen osien poistamista ennen käyttöä jatkokäsittelyn helpottamiseksi [16]. Työn esikäsittelymenetelminä olivat keskiarvon poisto, joka keskittää datan nollassa tasolla sekä ylipäästösuodatus, joka lisäksi hillitsee kiihtyvyyssanturin ns. nollassa tasolla hidasta valumaa signaalitasossa.

3.2.1 Keskiarvon poisto


Keskiarvon poistamisella on useita tarkoituksia mutta pääasiallisesti se keskittää datan nollassa ympäristöön, mikä usein helpottaa algoritmien työtä sillä tämän jälkeen data on numeerisesti stabiilimpi. Tämä johtuu skaalan tasoittumisesta. Keskiarvon poisto voi myös rajoittaa rajatapauksien vaikutusta käytettävään algoritmiin tuoden tarkempia tuloksia. Myös datan tulkittavuus voi parantua, sillä keskiarvon poisto hillitsee datassa mahdollisesti olevaa keskiarvon vakioetäisyyttä tai hitaasti muuttuvaa etäisyyttä nollassa (engl. offset). Keskiarvon poiston vaikutus kuvassa 3.2.



Kuva 3.2 Tutkimushenkilön kurkunpään kiihtyvyyssanturin signaalit ennen ja jälkeen keskiarvon poiston.

3.2.2 Ylipäästösuodatin

Vahvasti matalataajuisista kohinaa tai hidasta anturien valumaa sisältävää anturisignaalia voidaan parantaa ylipäästösuodatuksella, jolloin asetetun rajataajuuden alle jäävä signaali suodattuu pois. Ylipäästösuodatus toteutettiin finite impulse response (FIR) suodattimena. FIR-suodattimen rajataajuudeksi valittiin aiempien töiden nojalla 0.1 Hz. Ylipäästösuodatuksen vaikutus on näkyvässä kuvassa 3.3.



Kuva 3.3 Tutkimushenkilön kurkunpään kiihtyvyyssanturin signaalit ennen ja jälkeen ylipäästösuodatuksen.

FIR-suodatus aiheuttaa signaaliin viivettä, joten viive korjattiin lisäämällä signaaleiden loppuun ennen suodatusta $\frac{N}{2}$ nollaa, jossa N on FIR-suotimen kertaluku. Suodatuksen jälkeen signaalin alusta poistettiin $\frac{N}{2}$ näytettä.

3.3 Piirteiden valinta

Kuten työn datan osalta, korkeadimensionaalinen data-analyysi on haaste tutkijoille ja insinööreille koneoppimisen ja tiedon louhinnan aloilla. Piirteiden valinta tarjoaa tehokkaan tavan ratkaista tämä ongelma poistamalla epäolennaiset ja ylimääräiset piirteet. Tämä voi lyhentää laskenta-aikaa, parantaa oppimistarkkuutta ja helpottaa oppimismallin tai -tietojen parempaa ymmärtämistä [17].

Erilaisia piirrevaihtoehtoja tarkasteltiin tässä työssä sekä aika- että taajuustason piirteinä. Edellä mainitussa on kyse jännitetasoista mittasignaaleissa ajan funktiona, jotka vastaavat digitaalisen signaalin aikariippuvia amplituditasoja analyysiympäristössä. Jälkimmäisessä kyse on signaalin taajuuskomponenttien voimakkuudesta eli määrällisestä läsnäolosta signaalissa. Molemmilla tasoilla tarkasteltiin myös pääkomponenttianalyysin merkitystä oleellisten datapiirteiden yhdistelyssä ja valinnassa.

3.3.1 Aikatason piirteet

Työn raaka mittadata oli aikatasossa eteneviä digitaalisiksi amplituditasoiksi näytteistettyjä aikasarjoja. Tämän tyyppinen jatkuva pitkä signaali tarvitsee luokituksen mahdollistamiseksi jakaa lyhyen aikavälin näytteiksi. Tavoitteena tässä jakamisessa on riittävän pitkä näytepituus, jotta tunnistettavat nielaisut ilmenevät niissä kokonaisuudessaan, mutta toisaalta riittävän lyhyt näytepituus, jotta nielaisut eivät sekoitu liian suureen määrään muuta signaalisisältöä. Näytteiksi jakamiseksi kunkin tutkimushenkilön aikasarjat ikkunoihin 250 näytteen eli 2.5 s mittaisiksi tapahtumiksi, kun näytetaajuutena oli aiemmin mainittu 100 Hz. Ikkunoidut tapahtumahetket määriteltiin joko nielaisuksi tai passiivisuudeksi, ja tämä tapahtui ennalta videoinnin perusteella tapahtuneen asiantuntijaluokituksen mukaan. Videoluokituksessa esiintyy kuitenkin viivettä luokittelijan reaktioajan suhteessa nähtyyn tapahtumaan. Tämä huomioitiin tapahtumaikkunoiden luokituksessa tarkistamalla 100 näytettä ennen ja jälkeen tapahtumaikkunan, mahdollisen nielureaktiomerkin varalta. Jos tässä ns. offset ajassa tai näyteikkunassa oli nielaisumerkintä, näyte luokiteltiin nielaisuksi.

Aikatason tapahtumaikkunoista laskettiin luokittelupiirteiksi yhdeksän piirrettä. Piirteet on esitetty taulukossa 3.1.

Piirteet
Keskiarvo
Keskihajonta
Mediaani
Mediaanin absoluuttinen hajonta
Huipukkuus
Vinous
Lokaali minimi
Lokaali maksimi
Maksimim ja minimin erotus

Taulukko 3.1 Aikatason piirteet

Jokainen piirteistä laskettiin tapahtumaikkunan jokaista itsenäistä signaalikanavaa kohden (esim. leuan alla olevan kiihtyvyyssanturin x-suunta). Yhdessä anturikokonaisuudessa tämä merkitsi kuutta signaalia sekä kulmanopeus- että kiihtyvyyssanturin kolmisuuntaisuuden takia. Näistä luotiin yksi pitkä piirrevektori ketjutamalla jonoksi kanavakohtaiset piirteet eri kanavien yli. Yksittäisen anturikokonaisuuden piirrevektorin dimensioiksi tuli siis 54 mittapistettä. Kaikkien seitsemän anturikokonaisuuden käyttö ja peräkkäin asettelu piirrevektoriksi nosti dimension 378 mittapisteeseen.

3.3.2 Taajuustason piirteet

Data ikkunoitiin kuten edellä aikatasossa. Taajuustason piirteistämiseksi aikatasosta siirrytään taajuustason tehosppektriin. Työssä tämä tapahtuu Fourier muunnoksen nopeaksi implementoitua Fast Fourier Transform (FFT) algoritmia hyödyntäen. Logaritminen tehosppektri saadaan, kun Fourier muunnoksen itseisarvosta otetaan kymmenkantainen logaritmi, joka kerrotaan 20:llä. Fourier muunnoksen reaalisignaaleille aiheuttama peilautuminen poistettiin lopputuloksesta.

Laskenta tehtiin aikatasossa ikkunoiduille kulmanopeus- ja kiihtyvyyssantureiden signaaleille ja näistä lasketut tehosppektrit asetettiin jonoksi. Lopputulemana käytettävien anturikokonaisuuksien mukainen taajuustason piirrematriisi. Yksi kuuden sensorisignaalin anturikokonaisuus vastasi 756 taajuuskomponenttia jokaista tapahtumanäytettä kohden. Kaikkia anturikokonaisuuksia hyödyntäessä kokonaisdimensio oli 5292 mittapistettä.

3.3.3 Pääkomponenttianalyysi

Suuret tietojoukot ovat yhä yleisempiä, ja niitä on usein vaikea tulkita. Pääkomponenttianalyysi (PCA) on tekniikka, jolla vähennetään tällaisten tietojoukkojen dimensiota, lisätään tulkittavuutta mutta samalla minimoidaan tiedon menetys. PCA tekee sen luomalla uusia korreloimattomia muuttujia, jotka yhdessä maksimoivat alkuperäisessä signaalissa olevan varianssin säilymisen kuvauksessa. Tällaisten uusien muuttujien, pääkomponenttien, löytäminen pelkistyy ominaisarvo/ominaisvektoriongelman ratkaisemiseen. Uudet muuttujat määritellään käsillä olevalla tietojoukolla, ei apriorisuudella, mikä tekee PCA:sta adaptiivisen data-analyysitekniikan. Se on adaptiivinen myös toisessa mielessä, koska tekniikasta on kehitetty muunnelmia, jotka on räätälöity erilaisiin tietotyyppeihin ja -rakenteisiin. [23]

Työssä koeltiin pääkomponenttianalyysin hyödyntämistä datan moniulotteisuuden rajaamiseksi. Tarkoituksena olevalla piirteiden dimensionaalisuuden rajaamisella tavoiteltiin parempaa hajautumista luokille sekä ylisovituksen hillitsemistä.

3.4 Käytetyt luokittimet

3.4.1 Lineaarinen regressio

Lineaarinen regressio valittiin alustavaksi pohjamalliksi. Lineaarinen regressio on helposti implementoitavissa ja suoriutuu luokittimena usein kohtuullisen hyvin. Malli ei kuitenkaan välttämättä kykene hyödyntämään kaikkia potentiaalisia parannuksia tai muutoksia menetelmäksetju aiemmissa vaiheissa, mikäli ne vaikuttavat luokkien epälineaariseen mutta eivät lineaariseen erottuvuuteen. Malli toimi siis lähtökohtana menetelmäkehitykselle, jonka pohjalta suorituskykyä pyrittiin parantamaan käyttämällä myös epälineaarista luokitusta

3.4.2 Tukivektorikone

Työn toiseksi malliksi valikoitui tukivektorikone. Tukivektorikone on osoittautunut toimivan hyvin tilanteessa, jossa opetusdataa on vähän. Datan vähyys sulkee esimerkiksi neuroverkot lähtökohtaisesti pois vaihtoehtoista. Monille muille malleilla taas työn korkeadimensionaalinen data useine anturikokoonpanoineen olisi ylisovittamisen muodossa suuri haaste. Joustavan marginaalin tukivektorikone kuitenkin mahdollistaa luokkien hajauttamisen ilman liiallista ylisovitusta salliessaan myös virheellisiä luokituksia rajauksessa.

Työssä C-SVM optimointiongelman 2.12 ratkaisu implementoitiin ns. brute-force koodilla haarukoiden eri vaihtoehtoja regularisaatioparametrille C sekä joustotermille ξ . Vaihtoehdot käytiin läpi kolmella ydinvaihtoehdolla (engl. kernel) jotka olivat gaussinen, lineaarinen ja polynominen. C-SVM opetettiin määritellyillä vaihtoehtoilla ja testattiin tarkkuutta ns. kehitysjoukolla, jolloin parhaan tuloksen tuottamat parametrit valittiin ja luokitin, opetettiin uudesta koko opetusdatalla, koska aiemmin siitä oli varattuna osa kehitysjoukossa.

4. KOKEET

Datan epätasaisen luokkajakauman vuoksi kahden luokan tasaamisessa käytettiin satunnaisvalintaa. On ilmeistä, että sellaisenaan luokissa olisi vallinnut huomattava epätasapaino, ei-nielaisuuksien tapahtuvien hetkien määrän vuoksi. Tasaus tehtiin alinäytteistämällä ei-nielaisuuksien luokkaa valitsemalla satunnaisesti nielaisuuksien määrän verran ei-nielaisuuksia. Tämän vuoksi tulosten pitävyyttä pyrittiin mahdollisimman paljon, konetehon ja ajan puitteissa, tasoittamaan ajamalla kokeet eri matlabin rng-satunnaislukufunktion erilaisilla siemenluvuilla. Kyseinen funktio oli vastuussa ei-nielaisuuksien tapahtuvien hetkien satunnaisvalinnasta todellisuudessa huomattavasti suuremmasta joukosta.

17 koehenkilön puitteissa käytettiin kaikkiin koeajoihin yhden testihenkilön menetelmää (Engl. leave one subject out, LOSO), jossa opetusdatana käytetään kaikkia paitsi yhden henkilön mittauksia ja luokitinta koetetaan tällä datalla. Tämä toistetaan kaikkien koehenkilöiden kohdalla ja lopuksi lasketaan näistä tuloksista keskiarvo ja keskihajonta.

4.1 Mallin optimointi

Tukivektorikoneen mallissa oli kaksi optimoitavaa hyperparametria C ja ξ . Automaattiset työkalut osoittautuivat kuitenkin haasteelliseksi. Ohjelmiston integroitu ristiinvalidointitapa, joka valitsi sattumanvaraisia näytteitä tasaisesti datasta tietyllä prosenttisuudella, ei soveltunut käytössä olevaan dataan.

Näin ollen mallin optimointiin implementoitiin hyperparametrien ja kernel-vaihtoehtojen ns. brute-force sovitin, joka hyödynsi kahden tutkimushenkilön dataa tuloksien todentamiseen. Sovitin kävi läpi eri kernel-, regulointitermi- ja joustotermivaihtoehdot ennalta määrätystä parametriarvojoukosta. Näistä vaihtoehdoista sovitin valitsi parhaan yhdistelmän, jota käytettiin jatkossa mallin opettamiseen kaikkea dataa hyödyntäen. Optimoitua mallia testattiin pohjatasoisen lineaarisen regression mallia vastaan.

4.2 Esikäsittelyn vaikutus

Esikäsittelyn vaikutusta tutkittiin ajamalla erilaiset menetelmäkettjut aloittaen esikäsittelystä joko keskiarvon poistamisella tai ylipäästäsuodatuksella. Näiden kahden välille pyrittiin havaitsemaan merkityksellisiä eroja liittyen kulloinkin käytössä olevaan piirre-, sensori ja mallivalintaan.

4.3 Piirrevalinnan merkitys

Aikasarjat piirteistettiin sekä aikatasossa sekä taajuustasossa. Piirteistys näissä kahdessa käydään läpi tarkemmin menetelmissä. Koeasetelmana ja tarkoituksena verrata aikataso- ja taajuustason lopullisia tarkkuusmittarien tuloksia toisiinsa sekä pääkomponenttianalyysin hyötyä molemmille menetelmille.

4.4 Sensorivalinta

Seitsemän erillistä sensorikokonaisuutta mittasi yhteensä 42 mittasignaalia. Sijainnit leuan alla, kieliluu vasen, kieliluu oikea, kurkunpää, alavasen, alaoikea ja niska keräsivät jokainen kuusi signaalia, joista kolme kiihtyvyyssanturin signaalit x -, y - ja z -tasossa ja toiset kolme kulmanopeusanturin x -, y - ja z -tasot.

Yksittäisten sensorisijaintien luokitustarkkuutta testattiin käyttämällä opetuksessa ja luokituksessa vain kiihdyvyystietojen, vain kulmanopeustietojen sekä molempien anturikokonaisuuksien mittauksia. Yksittäisten mittapisteiden lisäksi tutkittiin kombinaatioiden tarkkuuksia. Anturikombinaatiot on lueteltu taulukossa 4.1.

Anturikombinaatio
kieliluu vasen, kieliluu oikea
kieliluu vasen, kieliluu oikea, kurkunpää
leuan alla, kieliluu vasen, kieliluu oikea
leuan alla, kurkunpää
kaikki sijainnit

Taulukko 4.1 sensorivalintojen anturikombinaatiot

Yllä esitetyt anturikombinaatiot kuten yksittäisetkin anturit testattiin käyttämällä vain kulmanopeus-, vain kiihdyvyys- ja molempia antureita. Tulokset kerättiin samaa menetelmäkettua hyödyntäen.

4.5 Satunnaisvalinta

Satunnaisvalinta oli läsnä kaikissa kokeissa. Ei nielaisiksi luokiteltavia tapahtumia oli huomattavasti suurempi määrä kuin nielaisiksi luokiteltavia. Tämän vuoksi piti ei nielaisuja valita sattumanvaraisesti opetusdatasta vastaava määrä tasapainoittamaan luokat. Tämän valikoitumisen vaikutusta tuloksiin seurattiin ajamalla kokeet useilla eri satunnaisfunktion ns. seed arvoilla varmistaakseen, ettei luokitustarkkuus riipu vain hyvin valikoiduista tapahtumanäytteistä.

4.6 Mittarit

Luokitustulosten ja koeasetelmien suoriutumisen pääasiallinen mittari työssä on F1-tulos (engl. F1-score). F1-score lasketaan hyödyntäen kahta muuta tarkkuuden mittaria precision sekä recall. Precision mittaa todellisten positiivisten, tässä työssä nielaisujen suhdetta kaikkiin nielaisiksi luokiteltuihin näytteisiin. Recall määrittää kuinka moni nielaisuista tuli oikeasti luokiteltua nielaisuiksi. Työn lopullinen vertailumittari F1-tulos on näiden kahden harmoninen keskiarvo. F1-tulos luokalle k lasketaan kaavalla

$$F1_k = \frac{2}{p_k^{-1} + r_k^{-1}} \quad (4.6)$$

Jossa p_k on precision luokalle k , joka lasketaan kaavalla

$$p_k = \frac{tp_k}{tp_k + vp_k} \quad (4.7)$$

jossa tp_k on todelliset positiiviset luokassa ja vp_k on väärät positiiviset luokassa k . Recall termi r_k luokalle k lasketaan kaavalla

$$r_k = \frac{tp_k}{tp_k + vn_k} \quad (4.8)$$

jossa vn_k on väärät negatiiviset luokalle k .

5. TULOKSET

Taulukko 5.1 yksi esittää malli-, esikäsitteily- ja piirrevalinnan merkityksen menetelmäketojussa käyttäen kaikkia seitsemää anturikokonaisuutta, joka tuotti aina poikkeuksetta tarkimmat tulokset. Taulukon tulokset ovat kahden eri satunnaisvalinnan keskiarvoja.

Luokitin	Esikäsitteily	Piirteistö	PCA	F1 keskiarvo
Lineaarinen regressio	Keskiarvon poisto	Aikataso	Ei	77,30 %
Lineaarinen regressio	Keskiarvon poisto	Aikataso	Kyllä	57,75 %
Lineaarinen regressio	Ylipäästösuodatus	Aikataso	Ei	76,83 %
Lineaarinen regressio	Ylipäästösuodatus	Aikataso	Kyllä	64,13 %
Lineaarinen regressio	Keskiarvon poisto	Taajuustaso	Ei	67,41 %
Lineaarinen regressio	Keskiarvon poisto	Taajuustaso	Kyllä	70,92 %
Lineaarinen regressio	Ylipäästösuodatus	Taajuustaso	Ei	67,91 %
Lineaarinen regressio	Ylipäästösuodatus	Taajuustaso	Kyllä	69,58 %
Tukivektorikone	Keskiarvon poisto	Aikataso	Ei	78,76 %
Tukivektorikone	Keskiarvon poisto	Aikataso	Kyllä	58,12 %
Tukivektorikone	Ylipäästösuodatus	Aikataso	Ei	75,72 %
Tukivektorikone	Ylipäästösuodatus	Aikataso	Kyllä	63,43 %
Tukivektorikone	Keskiarvon poisto	Taajuustaso	Ei	80,28 %
Tukivektorikone	Keskiarvon poisto	Taajuustaso	Kyllä	80,42 %
Tukivektorikone	Ylipäästösuodatus	Taajuustaso	Ei	73,09 %
Tukivektorikone	Ylipäästösuodatus	Taajuustaso	Kyllä	81,43 %

Taulukko 5.1 Menetelmäketojujen tulokset

Tarkimman tuloksen tuotti dataan optimoitu tukivektorikone hyödyntäen esikäsitteilyssä ylipäästösuodatusta ja piirteiden valinnassa PCA:ta taajustason piirteillä. Sekä lineaarisen regressio ja tukivektorikoneen mallissa taajustason piirteistö selvästi hyötyi PCA:n käytöstä, kun taas aikataso tarkkuutta se heikensi.

Satunnaisvalinta ei aiheuttanut tarkimman menetelmäketojun tuloksiin merkittäviä muutoksia. Viiden eri satunnaisluvun tulokset opetusdatan sovituksesta sekä testiluokituksesta on esitetty taulukossa 5.2.

Satunnaisvalinta	Opetus	Luokitustesti
	F1 ja keskihajonta	
Luokitus 1	92,96 % ($\pm 0,38$ %)	80,86 % ($\pm 5,26$ %)
Luokitus 2	92,84 % ($\pm 0,41$ %)	82,01 % ($\pm 5,85$ %)
Luokitus 3	92,94 % ($\pm 0,67$ %)	81,31 % ($\pm 4,43$ %)
Luokitus 4	93,02 % ($\pm 0,42$ %)	82,04 % ($\pm 5,40$ %)
Luokitus 5	92,98 % ($\pm 0,45$ %)	82,22 % ($\pm 4,40$ %)
Kaikkien keskiarvo	92,95 % ($\pm 0,46$ %)	81,67 % ($\pm 5,07$ %)

Taulukko 5.2 Parhaan menetelmäketojun satunnaisvalinnan merkitys

Paras yksittäinen luokitus saavutti tarkkuudeksi F1-tulosten keskiarvon LOSO-menetelmässä 82,22 %, jolloin keskihajonta oli 4,4 % eri koehenkilöiden kesken. Opetusdatan tarkkuudesta huomataan, että mallin optimointi oli onnistunut.

Yksittäisten anturivalintojen ja niiden yhdistelmien vaikutus menetelmäketojun tarkkuuteen on esitetty taulukossa 5.3. Niitä tutkiessa käytössä ollut menetelmäketojun malli oli tukivektorikone, hyödyntäen ylipäästösuodatusta taajustasossa, mutta PCA ei ollut käytössä.

Anturien sijainti	Käytössä olleet anturit		
	Kiihtyvyyssanturit	Kulmanopeusanturit	Molemmat anturit
	Keskiarvo F1		
Leuan alla	70,04 %	70,11 %	73,05 %
Kieliluu vasen	71,54 %	71,63 %	75,17 %
Kieliluu oikea	68,49 %	68,89 %	71,44 %
Kurkunpää	72,59 %	68,48 %	75,25 %
Ala vasen	63,68 %	63,44 %	67,78 %
Ala oikea	65,26 %	66,44 %	69,38 %
Niska	67,39 %	67,71 %	70,23 %
Kieliluu vasen ja oikea	72,50 %	72,48 %	76,26 %
Kieliluu vasen ja oikea, kurkunpää	75,25 %	74,79 %	78,60 %
Leuan alla, kieliluu vasen ja oikea	74,40 %	76,17 %	79,31 %
Leuan alla, kurkunpää	74,79 %	75,10 %	78,74 %
Kaikki anturit	77,97 %	79,44 %	81,44 %

Taulukko 5.3 Anturikombinaatioiden vaikutus luokitustarkkuuteen

Oletettavasti PCA:n käyttö olisi tarkentanut tuloksia samassa suhteessa, koska taajuustasossa tämä trendi on nähtävissä kaikissa työn tuloksissa taajuustasossa. Kuitenkin anturien merkitys tarkkuuteen on havaittavissa hyvin myös ilman PCA:n käyttöä. Tulokset ovat viiden erillisen satunnaisvalinnan F1-tuloksen keskiarvoja.

Tarkkuuden kannalta olennaisiksi osoittautuivat yksittäisinä antureina kurkunpään ja leuan alle sekä kieliluun molemmille puolille sijoitetut anturit. Näiden antureiden erilaiset kahden ja kolmen anturin yhdistelmät tuottivat merkittäviä tuloksia, kun taas alhaalla vasemmalla, alhaalla oikealla ja niskassa sijaitsevat anturit tuottivat itsenäisesti heikompia tuloksia ja paransivat tarkkuutta yhdistelmänä muihin vain hieman.

6. YHTEENVETO

Työssä tarkasteltiin vaihtoehtoisten menetelmien vaikutusta menetelmäketjun eri osissa ja pyrittiin etsimään työn datalle parhaita tarkkuutta tuottava menetelmäketju. Samalla tehtiin havaintoja anturien ja anturikokonaisuuksien tarkkuuksista. Esimerkiksi akun kulutuksen kannalta pienempi määrä, jolla pääsee vastaavaan tarkkuuteen, olisi edullista. Työn malliksi valittu SVM suoriutui hyvällä tarkkuudella luodun optimointikoodin jälkeen. Tarkkuuden vaihdellessa hieman koehenkilön mukaan, mutta kuitenkin yltäen keskiarvillisesti 82,22 %. Tällöin menetelmäketjun kulku oli signaalidatan ylipäästösuodatus esikäsitelyssä, taajuustason piirteistön luominen FFT:tä hyödyntäen sekä PCAn käyttö taajuustason piirteiden dimensionaalisuuden pienentämiseen.

Työssä kävi selväksi millainen esikäsitely ja piirteistö työn datalle toimii. Samoin esikäsitelyn ja piirteistön suhde toisiinsa kävi ilmi, sillä piirteistön ollessa aikatasossa toimivat erilaiset menetelmät kuin taajuustasossa. Vaikka opetuksessa ja testauksessa käytettyjen ei-nielaisua koskevien ajanhetkien satunnaisvalinnalla oli työn tuloksiin jonkun verran merkitystä, havaittiin tämä lopulta kohtuullisen pieneksi ja näin ollen tuloksia voidaan pitää luotettavana.

Työ jättää kehitettävää menetelmäketjuun ja antaa suuntaa, että älykauluri olisi mahdollisesti toteutettavissa pienemmällä laitteistoilla. Tämä mahdollistaisi helpommin kaulurin tuottamisen akkukäyttöiseksi ja käytettäväksi missä tahansa ympäristössä keräten luotettavaa dataa myös kliinisten olosuhteiden ulkopuolella.

LÄHTEET

- [1] Adkins, C., Takakura, W., Spiegel, B. M. R., Lu, M., Vera-Llonch, M., Williams, J., & Almario, C. V. (2020). Prevalence and characteristics of dysphagia based on a population-based survey. *Clinical Gastroenterology and Hepatology*, 20(3), 1970–1979.
- [2] Törmä, S., Ihalainen, T., Palovuori, K., Sipilä, E. & Virkki, J. (2022). Recognizing swallowing movements using a textile-based device. *Textile Research Journal*, 004051752211154. <https://doi.org/10.1177/00405175221115470>
- [3] Suomen Dysfagian kuntoutusyhdistys ry. (n.d.). *Mikä on dysfagia?* . Mikä on dysfagia? – Suomen Dysfagian kuntoutusyhdistys ry. Retrieved November 10, 2022, from <https://dysfagia.fi/mika-on-dysfagia/>
- [4] Shai, S.-S. & Shai, B.-D. (2014). *Understanding Machine Learning: From Theory to Algorithms* (1st ed.). Cambridge University Press. <https://www.cs.huji.ac.il/w~shais/UnderstandingMachineLearning/understanding-machine-learning-theory-algorithms.pdf> pp. 22-23
- [5] Su, X. G. (2009). Linear Regression Analysis. *Linear Regression Analysis*, pp. 1-10. <https://doi.org/10.1142/6986>
- [6] G. -X. Yuan, C. -H. Ho, & C. -J. Lin, (2012). Recent Advances of Large-Scale Linear Classification *Proc. IEEE*, 100(9), 2584-2603, Sept. 2012, doi: 10.1109/JPROC.2012.2188013.
- [7] Pardoe, I., Simon, L. & Young, D. (n.d.). 5.4 - A Matrix Formulation of the Multiple Regression Model | STAT 462. Retrieved November 10, 2022, from <https://online.stat.psu.edu/stat462/node/132/>
- [8] Cortes, C. & Vapnik, V. (1995). Support-vector networks. *Machine Learning*, 20(3), 273-297. <https://doi.org/10.1007/bf00994018>
- [9] Chervonenkis, A. Y. (2013). Early History of Support Vector Machines. *Empirical Inference*, 13-20. https://doi.org/10.1007/978-3-642-41136-6_3
- [10] Boser, B. E., Guyon, I. M. & Vapnik, V. N. (1992). A training algorithm for optimal margin classifiers. Proc. Fifth Annual Workshop on Computational Learning Theory - COLT '92. <https://doi.org/10.1145/130385.130401>
- [11] *Support Vector Machines for Binary Classification - MATLAB & Simulink - MathWorks India*. (n.d.). Retrieved November 10, 2022, from <https://in.mathworks.com/help/stats/support-vector-machines-for-binary-classification.html>
- [12] Celeste, M., Azadeh, K., Sejdić, E., Berall, G. & Chau, T. (2012). Quantitative classification of pediatric swallowing through accelerometry. *Journal of NeuroEngineering and Rehabilitation*, 9(1). <https://doi.org/10.1186/1743-0003-9-34>
- [13] J. H. Lim, P. M. Djuric, & M. Stanacevic (2021), "Classification of Swallowing Foods Using Machine Learning Algorithms," *Proc. 2021 International Conference on Electrical, Computer and Energy Technologies (ICECET)*, 2021, pp. 1-4, doi: 10.1109/ICECET52533.2021.9698484.
- [14] L. J. Lazareck, & Z. M. K. Moussavi (2004), "Classification of normal and dysphagic swallows by acoustical means," in *IEEE Transactions on Biomedical Engineering*, 51(12), pp. 2103-2112, Dec. 2004, doi: 10.1109/TBME.2004.836504.
- [15] L. Wei, Y. Pan, Y. Zhong, & R. Huan (2018). A Novel Approach for Swallow Detection by Fusing Throat Acceleration and PPG Signal. *Proc. 40th Annual International Conference of the IEEE Engineering in Medicine and Biology Society (EMBC)*, 2018, pp. 4293-4296, doi: 10.1109/EMBC.2018.8513380.
- [16] *Guide To Data Cleaning: Definition, Benefits, Components, And How To Clean Your Data*. (n.d.). Tableau. Retrieved November 10, 2022, from <https://www.tableau.com/learn/articles/what-is-data-cleaning>
- [17] Cai, J., Luo, J., Wang, S., & Yang, S. (2018). Feature selection in machine learning: A new perspective. *Neurocomputing*, 300, 70-79. <https://doi.org/10.1016/j.neucom.2017.11.077>
- [18] Moradi, S., Tapak, L., & Afshar, S. (2022). Identification of Novel Noninvasive Diagnostics Biomarkers in the Parkinson's Diseases and Improving the Disease Classification Using Support Vector Machine. *BioMed Research International*, 2022, 1-8. <https://doi.org/10.1155/2022/5009892>

- [19] Support vector machine. (2022, October 19). Wikipedia. https://en.wikipedia.org/wiki/Support_vector_machine
- [20] Rhys, H. I. (2020). Machine Learning with R, the tidyverse, and mlr. Manning Publications.
- [21] James, G., Witten, D., Hastie, T., & Tibshirani, R. (2013). An Introduction to Statistical Learning. Springer Texts in Statistics. <https://doi.org/10.1007/978-1-4614-7138-7>
- [22] Math behind SVM(Support Vector Machine) - MLMath.io. (2021, December 7). Medium. <https://ankit-nitjsr13.medium.com/math-behind-svm-support-vector-machine-864e58977fdb>
- [23] Jolliffe, I. T., & Cadima, J. (2016). Principal component analysis: a review and recent developments. *Philosophical Transactions of the Royal Society A: Mathematical, Physical and Engineering Sciences*, 374(2065), 20150202. <https://doi.org/10.1098/rsta.2015.0202>
- [24] Dudik, J. M., Coyle, J. L., El-Jaroudi, A., Mao, Z. H., Sun, M., & Sejdić, E. (2018). Deep learning for classification of normal swallows in adults. *Neurocomputing*, 285, 1-9. <https://doi.org/10.1016/j.neucom.2017.12.059>