

Precisionsodling av vall

– Sensormätning som analysredskap för
proteininnehåll och skörd

Precision agriculture of ley crop

– *Remote sensing as an analytic tool for protein content
and yield*

Emma Hellstedt



Kandidatuppsats i biologi
Agronomprogrammet – mark/växt

Precisionsodling av vall – Sensormätning som analysredskap för proteininnehåll och skörd

Precision agriculture of ley crop – Remote sensing as an analytic tool for protein content and yield

Emma Hellstedt

Handledare: Johanna Wetterlind, institutionen för mark och miljö, SLU

Biträdande handledare: Sofia Kämpe, Agroväst

Examinator: Bo Stenberg, institutionen för mark och miljö, SLU

Omfattning: 15 hp

Nivå och fördjupning: Grundnivå, G2E

Kurstitel: Självständigt arbete i biologi – kandidatarbete

Kurskod: EX0689

Program/utbildning: Agronomprogrammet – mark/växt 270 hp

Utgivningsort: Uppsala

Utgivningsår: 2017

Omslagsbild: Blandvall, foto Annika Arnesson 2003

Serietitel: Examensarbeten, Institutionen för mark och miljö, SLU

Delnummer i serien: 2017:15

Elektronisk publicering: <http://stud.epsilon.slu.se>

Nyckelord: sensormätning, hyperspektral, vegetationsindex, NDVI, GNDVI, SR, blandvall, gräsvall, PLS, fältförsök

Sveriges lantbruksuniversitet
Swedish University of Agricultural Sciences

Fakulteten för naturresurser och jordbruksvetenskap
Institutionen för mark och miljö

Sammanfattning

Vall odlas på 45 % av Sveriges åkerareal och vallen är en viktig gröda både ur växtföljdssynpunkt och för djurhållning. Det är också en gröda som skiljer sig från spannmålen genom skördetidpunkt, antal skördar och artsammansättning. I andra grödor som vete och korn finns sen 00-talet optiska sensorer som kan läsa av biomassa och kvävebehov i grödan, men på grund av vallens unika egenskaper kan inte tekniken med lätthet överföras till vall. Det finns några försök i Sverige med syfte att kartlägga sambanden mellan sensormätning och egenskaper i vallen. I det här arbetet presenteras data från ett pågående fältförsök i vall på Rådde försöksstation. Försöket består av tre gräsvallar och en blandvall varav en av gräsvallarna och blandvallen har fått fem olika N-givor. I samband med tre olika skördar har vi med en hyperspektral N-sensor mätt reflektansen från varje försök och i det här arbetet undersöks sambandet mellan reflektansen och biomassa, ts, råproteinhalt och proteinmängd genom två metoder. Dels genom en enkel linjär korrelation mellan fyra olika vegetationsindex (VI) och dels genom en multivariat linjär korrelation, Partial Least Squares regression (PLS), med hyperspektral data mellan 400-900 nm. Sambanden mellan hyperspektral data och analysvärdena användes i modeller som testades genom korsvalidering.

Resultaten från sammanställningen visar att det fanns samband mellan sensormätning och analysdata där de starkaste sambanden fanns mellan hyperspektral data och proteinmängd i gräsvallar. Bland VI var de innehållande gröna våglängder som gav starkast korrelation med samtliga analysvärden men generellt var korrelationen i blandvallarna svag. Vid skapandet av modeller utifrån sambanden var det proteinmängd och proteinhalt som gav högst r^2 -värde vid en validering och även sambandet mellan sensormätning och klöverandelen visade att en sensor i den här studien kunde läsa av mängden klöver med god korrelation.

Trots att hyperspektral data gav starkare korrelation än VI och trots att korrelationerna överlag var starka i gräsvallarna behövs ytterligare försök för att kunna dra några generella slutsatser.

Nyckelord: Sensormätning, Hyperspektral, Vegetationsindex, *NDVI*, *GNDVI*, *SR*, Blandvall, Gräsvall, *PLS*, Fältförsök

Abstract

Cultivated grassland is an important crop, both considering crop sequence and livestock keeping. It is cultivated on 45 % of the Swedish arable land, but it is a crop that differs from grains regarding time of harvest, number of harvests and composition of species. In other crops e.g. wheat and barley, it is possible to estimate biomass and nitrogen demand since the early 00's using remote sensing technology. But due to the unique properties of ley, the technology cannot be applied with ease.

There are a few ongoing Swedish projects where the correlation between remote sensing and ley properties is studied. One is at the experimental station in Rådde, which is where the data analysed in this report come from. In this particular field experiment, four different ley compositions are considered: three strict, different grasslands and one containing clover and grass. Five different amounts of nitrogen fertilizer have been applied to one of the grasses and to the mixed ley field. In connection to all three harvests, an N-sensor has been used to measure hyper spectral reflectance data. In this work the correlation between reflection and biomass, TS, raw protein content and protein amount have been examined by using two methods. The first one looks into single linear regression between the measured data and four vegetation indices (VI), and the second method uses Partial Least Squares regression (PLS) with hyperspectral data, 400-900nm. The multivariate PLS models were validated by cross validation.

The results show that there are relationships between remote sensing and measured data – where the strongest correlations can be found between hyperspectral data and protein amount in grasses. Among the studied VI's, the ones based on green wavelength bands yielded the highest correlations. Also, it can be noted that the ley containing clover had low correlations regarding all examined properties. When forming models with PLS, the highest correlations could be seen with the protein amount and raw protein content. Besides, it gets clear that the sensor used in this study makes a good estimation of the share of clover.

Despite the facts that hyperspectral data yields higher correlations than using VI's, but also that the correlations were high in cultivated grass, more research has to be done in order to make further general conclusions.

Keywords: Remote sensing, Hyperspectral, Vegetation indice, NDVI, GNDVI, SR, Grass, Clover, PLS, Field experiment.

Innehållsförteckning

Tabellförteckning	6
Figurförteckning	7
Förkortningar	9
1 Inledning	11
2 Bakgrund	13
2.1 Vallodling	13
2.2 Optisk sensormätning	14
2.3 Växtens optiska egenskaper	16
2.4 Vegetationsindex	18
2.5 Olika typer av grödsensorer	20
3 Fältförsök	21
3.1 Bakgrund till försöket	21
3.1.1 Försökets upplägg	21
3.1.2 Statistisk analys och hantering av data	22
4 Resultat fältförsök	24
4.1 Analysvärden – skörd och protein	24
4.2 VI	26
4.3 Hyperspektral data	27
4.3.1 Kalibrering	27
4.3.2 Validering	28
5 Diskussion	33
5.1 Diskussion av resultat	33
5.2 Slutsats	35
Referenslista	37
Tack	39

Tabellförteckning

Tabell 1. Försökleden	22
Tabell 2. Sammanställning av hur väl VI förklarar (r^2) variationen i biomassa, ts, råprotein och proteinmängd. Fetmarkerade värden representerar det högsta uppmätta värdet inom varje analys.	26
Tabell 3. Sammanställning av r^2 -värden från kalibrering (Kal) och validering (Val) för biomassa, torrs substans, proteinhalt och proteinmängd. * markerar värden visar r^2 -värden som är lägre än r^2 -värden i den enkla linjär regression med VI.	27

Figurförteckning

- Figur 1.* Det elektromagnetiska spektrumet med ett markerat område över de våglängdsområden som optiska sensorer mäter vid. Bild från Johanna wetterlind med några små modifikationer. 15
- Figur 2.* Beskriver växters optiska egenskaper i de våglängdsområden som en sensor mäter. Bild från Johanna Wetterlind. 16
- Figur 3.* Skillnaden i reflektansmönster då klorofyllkoncentrationen och LAI förändras. Bild från Knud Nissen. 17
- Figur 4.* Skördens storlek i kg/ha beroende på kvävetillförsel från samtliga 3 skördar. 24
- Figur 5.* Andel klöver i blandvallarna vid de tre skördarna. 25
- Figur 6.* Skördens råproteinhalt (g/kg ts) i alla tre skördar beroende på kvävetillförsel. 25
- Figur 7.* Beräknad mot uppmätt biomassa för PLS-kalibrering med hyperspektral data i gräsvallarna. Olika färger beskriver olika skördar och den nedre cirkeln ringar in 0 N-givorna. Den övre cirkeln ringar in led D. 28
- Figur 8.* Resultat från proteinmängdsbestämning med PLS-modell. Beräknad mot uppmätt proteinmängd i samtliga vallblandningar från alla skördar. Figuren visar både kalibrering och validering 29
- Figur 9.* Resultat från proteinhaltsbestämning med PLS-modell Beräknad mot uppmätt råproteinhalt i gräsvall från alla skördar. Figuren visar både kalibrering och validering 29
- Figur 10.* Predikterad mot uppmätt biomassa för korsvaliderade modeller gjorda med alla vallblandningar, gräsvallblandningar, led A och blandvallar. 30
- Figur 11.* Predikterad mot uppmätt ts för korsvaliderade modeller gjorda med alla vallblandningar, gräsvallblandningar, led A och blandvallar. 30
- Figur 12.* Beräknad mot uppmätt biomassa för PLS-kalibrering med hyperspektral data i gräsvallarna. Prediktioner av skörd 1 är skapade utifrån en modell av skörd 1. 31
- Figur 13.* Beräknad mot uppmätt biomassa för PLS-kalibrering med hyperspektral data i gräsvallarna. Prediktioner av skörd 2 är skapade utifrån en modell av skörd 1 och alltså inte korsvalidering. 31
- Figur 14.* Beräknad mot uppmätt klöverandel i alla skördar. 32

Förkortningar

GNDVI	Green normalized difference vegetation index
IR	Infrarött ljus
LAI	Leaf area index
MIR	Mid infrared radiation
NDVI	Normalized difference vegetation index
NIR	Nära infrarött ljus
NJV	Institutionen för norrländsk jordbruksvetenskap
nm	Nanometer
PLS	Partial least square
REIP	Red edge inflection point
SWIR	Short wave infrared radiation
TS	Torrsubstans
VI	Vegetationsindex

1 Inledning

Vall är den vanligaste grödan i Sverige och utgör 45 % av all åkerareal (jordbruksverket, u.å.). Det är en gröda med stor mångsidighet och vars produktionsmål anpassas efter gårdens inriktning, areal och biologiska möjligheter. Beroende på produktionsmål finns analyshjälpmedel för att förutsäga produktionspotentialen i vallen, exempelvis temperatursummor från vallprognos.se och grovfoderanalyser. En nackdel med de hjälpmedel som finns är att de inte tar hänsyn till variationer inom fältet och har en lång återkopplingstid (Parsons, 2017).

Precisionsodling, eller platsspecifik odling, är ett område av flera odlings-tekniska hjälpmedel där en platsspecifik behandling utförs i växande gröda med en direktåterkoppling av behovet (Engström et al., 2016).

Växten behöver näring och bland de essentiella växtnäringsämnen är kväve ett makronäringsämne som är starkt kopplat till skördens kvantitet och kvalitet. Upp till en viss mängd innebär normalt en ökad mängd kvävegödsling även en ökad skörd (Börling, 2016). Kväve är ett näringsämne som deltar i många biokemiska reaktioner i växten och ingår i bland annat syntetisering av protein och klorofyll. Sen 00-talet har sambandet mellan grödans ljusreflektans, klorofyll- och kväveinnehåll använts inom precisionsodling för att ge en platsspecifik och optimal mängd kväve i vete (Engström et al., 2016). Samma metod önskas kunna tillämpas i vallodling och fungera som ett analyshjälpmedel för att förutsäga biokemiska och biofysiska egenskaper direkt från bladen. Svårigheter med utveckling av precisionsodling i vall har varit att det är en gröda av flera arter, ibland kvävefixerande, samt att produktionsmålen mellan gårdar är olika att det är svårt att fylla allas behov.

I uppsatsen behandlas analysresultat och sensormätningar från ett fältförsök i vall tillsammans med en kort litteraturstudie. Försöket är en pågående undersökning om samband mellan sensormätning och växtens biokemiska egenskaper och består av fyra olika vallblandningar. Data är insamlad med en handburen hyperspektral N-Sensor och sensormätningar är utförda i samband med skörd. Prov-

skördar analyserades i laboratorium och de analysresultat som bearbetats i uppsatsen är biomassa, ts, råproteinhalt och proteinmängd. I resultatdelen jämförs analysvärden med fyra vegetationsindex skapade från sensormätningarna och även en enklare PLS-modellering från hyperspektral data med 51 våglängdsband på 10 nm mellan 400 och 900 nm.

Inledningsvis i detta arbete ges en bakgrund om vad sensormätning är och hur det kan användas för att mäta växtens biofysiska egenskaper. Därefter presenteras fältförsöket och sist presenteras och diskuteras resultat. En del av litteraturen är hämtad från rapporter gjorda på andra grödor, exempelvis stråsäd. Detta eftersom tekniken är mer etablerad där och mer kunskap finns att hämta – då utvecklingen inte har kommit lika långt inom vallodling.

Syftet med uppsatsen är att undersöka sambandet mellan sensormätning och analysvärden och det huvudsakliga målet är att hitta några samband som går att förklara med hjälp av litteraturen.

Frågeställningen är: kan reflektansmätningar användas som analyshjälpmedel för att läsa av biokemiska egenskaper i vällen och finns det resultat som tyder på att man kan läsa av egenskaper för att bestämma skörden?

2 Bakgrund

2.1 Vallodling

Vallodling skiljer sig från odling av andra grödor på flera punkter, men främst på grund av att den består av flera arter. Det kan vara vall av en eller flera gräsarter (*gräsvallar*) eller av både gräs- och baljväxtarter, så kallade *blandvallar* (Fogelfors, 2015). Gräs är en *monokotyledon* (enhjärtbladig växt) liksom våra vanliga spannmålsarter och omfattar ett mycket stort antal arter. Gräsen kan kategoriseras in i undergrupper av strågräs och bladgräs beroende på deras utvecklingsrytm och tillväxtsätt. De i Sverige odlade baljväxterna tillhör släktet *Lotus*, *Medicago* och *Trifolium* och är *dikotyledoner* (tvåhjärtbladiga växter). De kan i symbios med kvävefixerande bakterier fixera kväve från luften. Fördelar med en blandning av flera arter i en vall är att de kan kompensera för varandra (Swensson & Svensk mjölk, 2011). Om vintern är tuff kan de arter som klarat sig bättre täppa igen hålen efter de som utvintrat och genom att använda baljväxter, minska på kostnaden och användandet av kvävegödsel. En blandvall har dessutom ett större skördefenster än rena gräsvallar.

Vilka produktionsmål som finns vid vallodling varierar mellan olika gårdar och deras förutsättningar (Parsons, 2017). Det kan till exempel gälla djurslag; om det finns möjlighet att komplettera utfodringen med spannmål; proteinfoder; eller om vallen är den huvudsakliga proteinkällan (Börling, 2016). Det ställer i sin tur krav på den botaniska sammansättningen. Klöver (*fabaceae*) har i regel högre råproteinhalt än gräs (*poaceae*) vid samma kvävetillförsel, men om kvävegivan ökar så stiger gräsets råproteinhalt (Swensson & svensk mjölk, 2011). I vall som innehåller både gräs- och klöverarter minskar andelen klöver med en ökad giva eftersom gräset gynnas mer av det tillförda kvävet.

I matjorden förekommer kväve främst bundet i det organiska materialet och endast några procent som oorganiskt (Fogelfors, 2015). Kvävemängden är därför direkt kopplad till mängden organiskt material vilket varierar över fältet och från år till år. För att få önskad råproteinhalt och andel klöver kvar av den botaniska sammansättningen i skörden behöver därför både markens och gödselkvävegivans storlek beaktas. Genom att ha god kunskap om hur mycket kväve som marken levererar och grödan behöver skulle artsammansättningen och råproteinhalten kunna styras. Det finns även möjlighet att jämma ut variationer inom fältet och på så vis få en jämnare skörd totalt.

Gårdens avkastningspotential och hur mycket areal gården har att tillgå ställer också krav på skördetidpunkten. En tidig skörd prioriterar energiinnehållet (energitätheten) medan en senare prioriterar mängden biomassa (Swensson & svensk mjölk, 2011).

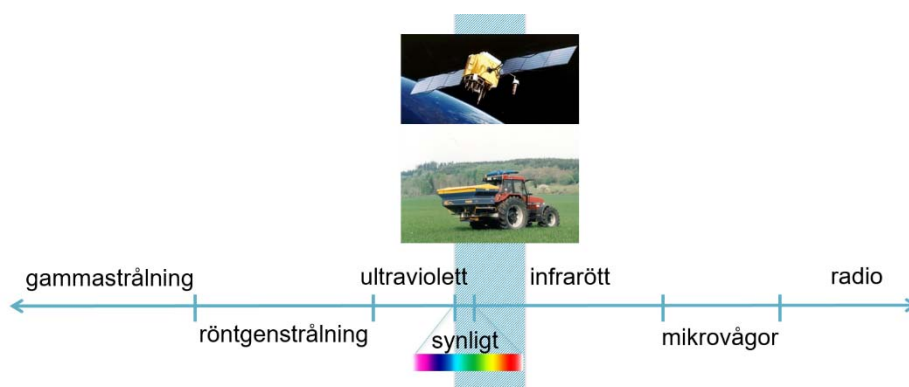
Idag finns flera metoder för att uppskatta vallens skördekvalitet, men ingen som tar hänsyn till variationer inom fält eller ger direkt återkoppling mellan observation och resultat (Parsons, 2017). Exempel på några metoder som används idag är tjänsten *vallprognos.se* som drivs av projektet Vallprognos och baseras på temperatursummor och klippta skördeprover som skickas till labb för analys (*vallprognos.se*, SLU Inst. för Husdjurens Utfodring och Vård med deltagare från flera företag och organisationer). Framtida möjligheter för att ge en direkt och platsspecifik fältuppskattning inkluderar sensorteknik och spektroskopi, men området är fortfarande underutvecklat inom vallodling.

Möjligheten att kunna använda sensormätningar även i vallen är efterfrågad, och många undrar om man kan använda optisk sensormätning för att förutsäga egenskaper som råprotein och biomassa i vall, både gräs- och blandvallar.

2.2 Optisk sensormätning

Fjärranalys är ett sätt att läsa av reflekterad energi från föremål eller ytor med hjälp av sensorer utan att vara i direktkontakt med det (Eastman, 2001). Det är en process som kan ske passivt eller aktivt. *Passiv* sensormätning innebär att redan befintliga energikällor används. Exempelvis är ögat en form av passiv sensor som kan läsa av ett objekt om det belyses av en extern energikälla som solljus eller en lampa. *Aktiv* sensormätning använder istället en egenskapad energikälla och ett exempel på aktiv sensor är radar (Ågren et al., 2013). Till skillnad från ett öga eller en digitalkamera, som endast kan läsa av blått, grönt och rött ljus, finns det sensorer som kan läsa av ett mycket bredare spektrum. Sensorer kan exempelvis sättas på ett traktortak, ett flygplan eller en satellit.

Den energi som vanligen används vid både passiv och aktiv sensormätning är *elektromagnetisk strålning*. Det är energi som rör sig med rytmiska vågrörelser beroende på sitt energiinnehåll (Campbell et al. 2015). Avståndet mellan två vågrörelser/vågtoppar kallas för våglängd och kan variera mellan mindre än en nanometer till flera kilometer. Strålning med korta våglängder har högt energiinnehåll och långa våglängder har lågt energiinnehåll och tillsammans utgör de det *elektromagnetiska spektrumet*. Generellt kan det elektromagnetiska spektrumet delas in i sju olika grupper. (1) gammastrålning, (2) röntgenstrålning, (3) ultraviolett ljus, (4) synligt ljus, (5) Infrarött ljus (IR), (6) mikrovågor och (7) radiovågor vilka visas i figur 1.



Figur 1. Det elektromagnetiska spektrumet med ett markerat område över de våglängdsområden som optiska sensorer mäter vid. Bild från Johanna wetterlind med några små modifikationer.


Optisk sensormätning är då sensorer fokuserar på synligt upp till infrarött ljus och är vanliga vid vegetationsmätningar. Beroende på hur breda våglängdsband som sensorerna kan läsa av delas sensorerna in i två former (Larsson, 2011). *Multispektrala sensorer* där ett fåtal våglängdsband läses av och *hyperspektrala sensorer* som över samma våglängdsområde delar upp reflektansen i flera våglängdsband. Ju smalare ett våglängdsband är desto mer specifik information kan analyseras. (Ågren et al., 2013; Eastman, 2001).

När elektromagnetisk strålning kommer i kontakt med ett ämne kan det *absorberas* (tas upp), *reflekteras* (studsa) eller *transmitteras* (gå igenom) (Campbell et al. 2015; Eastman, 2001). Solljus innehåller hela det elektromagnetiska spektrumet, men i atmosfären reflekteras och absorberas en stor del av det kortare våglängderna. Det leder till att de våglängder som når vegetationen är UV, synligt och IR-ljus (Eastman, 2001). Av dessa våglängder passar det gröna, röda och infraröda ljuset bäst för sensormätningar av vegetationen. Delvis beror det på att sensorlinserna absorberar en stor del av UV-

Ljuset och att våglängder i det blåa spektrumet påverkas av atmosfären. Men främst beror det på att växterna innehåller pigment som absorberar synligt ljus för att driva sin fotosyntes och reflekterar infrarött ljus beroende på cellstruktur och vattenhalt (Guyot, 1990). Det infraröda ljuset närmast det synliga kallas Nära infrarött, NIR (700 - 2 500 nm). I fjärranalyssammanhang delas NIR-området ofta in i två undergrupper: nära infrarött ljus NIR (700 – 1 300 nm) och *short wave infrared* (SWIR, 1 300 – 2 500 nm, ibland även kallat mellan-infrarött (MIR) (Heege & Eiko, 2013). Som figur 2 visar är skillnaden mellan reflektansen i det synliga ljuset och NIR stort hos växter.

2.3 Växtens optiska egenskaper

Grön biomassa, leaf area index (LAI), kväve- och vatteninnehåll i växten kan läsas av med hjälp av sensormätning samtidigt som det inte orsakar någon skada på grödan (Biewer et al., 2009). I figur 2 visas växters reflektansmönster i synligt ljus och IR-ljus. Det synliga ljuset absorberas med hjälp av pigment (klorofyll a och b, xantofyll, karotenoider & Antocyaniner) medan IR reflekteras beroende på cellstruktur och vattenhalt (Guyot, 1990).




Figur 2. Beskriver växters optiska egenskaper i de våglängdsområden som en sensor mäter. Bild från Johanna Wetterlind.

Synligt ljus

Växter använder synligt ljus som energikälla och alla högre växter uppvisar liknande absorptionsspektrum inom ramen för synligt ljus (Eastman, 2001). Absorptionen i pigment i bladen och i det synliga ljuset reflekteras endast 15 % av allt

inkommande ljus (Guyot, 1990). Av det står klorofyll a och b för 65 % av absorptionen och klorofyllkoncentrationen i bladen påverkar därför reflektansmönstret. Klorofyll har två absorptionsmaximum ett i det blåa spektrumet och ett i det röda vid 670 nm. Reflektansmaximum för klorofyll finns i det gröna spektrumet vid 550 nm (Guyot, 1990). Figur 3 visar hur reflektansmönstret ändras när klorofyllkoncentrationen i bladen ändras. När klorofyllkoncentrationen sjunker i bladen minskar växtens absorption och reflektansen ökar. Ett lågt klorofyllinnehåll gör att kvoten mellan NIR och grönt ljus minskar. Pigmenten i bladen, särskilt klorofyll består till stor del av kväve och det finns ett generellt samband mellan bladets kvävekoncentration och den fotosyntetiserande förmågan (Evans, 1989).



Figur 3. Skillnaden i reflektansmönster då klorofyllkoncentrationen och LAI förändras. Bild från Knud Nissen.

NIR

Infrarött ljus deltar inte i växternas energiförsörjning, men kan ändå säga mycket om växten och dess fysiologiska egenskaper (Guyot, 1990). Det nämndes tidigare att IR kan delas in i två undergrupper: NIR och SWIR. Deras reflektansmönster skiljer sig åt där NIR påverkas av bladets anatomiska struktur så som antalet cellager, storleken på celler och den relativa tjockleken på svampparenkymet. Reflektansen minskar med cellstorlek och ökar med antalet cellager och ett mer utvecklat svampparenkym. Dikotyledoner har ett mer välutvecklat svampparenkym än mo-

nokotyledoner och reflekterar en större andel NIR. Reflektansen i NIR skiljer sig alltså åt mellan arter (Eastman, 2001).

Andelen NIR som reflekteras beror också på LAI. En tät gröda med ett högt LAI påverkas lite av markens reflektans och med ett ökande LAI stiger reflektansen i NIR upp till en viss mättnadsgrad (Heege & Thiessen, 2013).

SWIR

Vatten har en god absorberande förmåga vid våglängder ovanför 1300 nm (mellan 14-1900 nm) och grödans reflektansmönster påverkas vid dessa våglängder av vatteninnehållet i bladen (Guyot, 1990).

2.4 Vegetationsindex

Genom att kombinera olika våglängdsband från växten, istället för att använda ett, kan växtens biofysiska, fysiologiska eller biokemiska egenskaper bestämmas bättre. (Larsson, 2011). Att kombinera olika våglängdsband kallas för vegetationsindex (VI) och är ett sätt att förklara intensiteten av reflektansen (Bannari et al., 1995). Det nämndes tidigare att skillnaden mellan synligt ljus och NIR varierar beroende på klorofyllkoncentration och LAI, och det sambandet har utnyttjats vid utvecklingen av VI. Beroende på vilka våglängdsband som används och beroende på hur de används i förhållande till varandra får man fram olika VI (Ågren et al., 2013).

Det är vanligt att VI består av våglängder från röd och nära infraröd strålning eftersom det röda ljuset absorberas av pigment och det nära infraröda ljuset reflekteras beroende på växtens cellstruktur (Biewer et al. 2009).

Vid val av vegetationsindex är det viktigt att ta hänsyn till växtens spektrala egenskaper (Pettersson, 2006).

1. Grönt ljus vid 550 nm är ett lokalt minimum för klorofyll absorption
2. Rött ljus vid 700 nm är också ett lokalt minimum för klorofyll absorption
3. Rött ljus vid 670 nm är ett lokalt maximum för klorofyll absorption.
4. Det infraröda bandet vid 780 nm där ljuset inte absorberas utan huvudsakligen reflekteras.

Exempel på olika vegetationsindex

Under de senaste åren har ett flertal olika VI tagits fram med fokus på att läsa av vegetationen (Eastman, 2001). Ett av de äldre och som ofta används som referens

är *Simple ratio* (SR) (Pettersson, 2006). Vid beräkning av SR tar man kvoten av nära infrarött ljus och synligt ljus, vanligen från det röda ljuset men även från det gröna förekommer (ekvation 1 och 2). Det ger då ett förhållande mellan hur mycket växten reflekterar i det nära infraröda ljuset i förhållande till reflektansen i det gröna- eller röda ljuset. En nackdel med att använda SR är att den inte är normalfördelad.

$$SR = \frac{NIR}{Red} = \frac{780 \text{ nm}}{670 \text{ nm}} \quad (1)$$

$$SR = \frac{NIR}{Green} = \frac{780 \text{ nm}}{550 \text{ nm}} \quad (2)$$

Ett annat vanligt förekommande VI är *Normalized Difference Vegetation Index* (NDVI, ekvation 3) och används ofta inom miljöövervakning och inom jordbruks system (Biewer et al., 2009). Det är ett VI som minimerar de topografiska effekterna samtidigt som det ger en linjär mätskala (Pettersson, 2006). Till skillnad från SR är NDVI normalfördelad, men båda används för att undersöka samband och kontraster mellan rött och infrarött ljus. NDVI korrelerar bra med klorofyllkoncentrationen och med LAI men vid höga LAI (vid LAI 3-4) har indexet nått sin övre gräns och fungerar därför sämre på täta bestånd

$$NDVI = \frac{NIR-Red}{NIR+Red} = \frac{780 \text{ nm}-670 \text{ nm}}{780 \text{ nm}+670 \text{ nm}} \quad (3)$$

Om klorofyllkoncentrationen är väldigt hög eller om LAI är över 3-4 kan reflektansen från det gröna spektrumet användas istället för det röda (Shanahan et al., 2001; Pettersson, 2006). *Green Normalized difference vegetation index* (GNDVI, ekvation 4) är en form av NDVI och beräknas på liknande vis, men med skillnad att reflektansen i det gröna spektrumet ställs i relation till den nära infraröda reflektansen. Både NDVI och GNDVI är känsliga för solinstrålningens vinkel (*azimut*) och bakgrundsreflektans från marken.

$$GNDVI = \frac{NIR-Green}{NIR+Green} = \frac{780 \text{ nm}-550 \text{ nm}}{780 \text{ nm}+550 \text{ nm}} \quad (4)$$

Om markreflektansen utgör en stor del av reflektansen finns det specifika index för att minska på dess påverkan (Biewer et al., 2009). Ett exempel är *red edge position* (REP) och utgör en specifik punkt mellan det röda och nära infraröda

ljusets reflektanskurva. Ett annat index för att minska markreflektansens påverkan är MSAVI och används bland annat av tjänsten CropSAT (Söderström et al., 2015).

2.5 Olika typer av grödsensorer

För att bedöma kvävebehovet i realtid i en gröda genom användning av optisk sensormätning finns flera kommersiella redskap på marknaden (Engström et al., 2016). Den kanske vanligaste grödsensorn i Sverige är Yara N-sensor som används på mer än 100 000 hektar. Andra exempel på kommersiella grödsensorer är Greenseeker, ISARIA och OptRx. Gemensamt för dessa, förutom att de läser av grödans reflektans i realtid, är att de är fordonsbaserade och används för spridning av handelsgödsel. Till Yara N-sensorn utvecklades tekniken först i höstvetete och lanserades under 00-talet, men idag finns även kalibreringar för malkorn och oljeväxter. Den utför reflektansmätningar i det synliga och nära infraröda spektrumet genom att mäta grödans reflektans och ger både värden för biomassa och kvävestatus (Yara, u.å.).

Exempel på tjänster som använder satellitburna sensorer är CropSAT.se där främst den kommersiella satelliten DMC används (Söderström et al., 2015). CropSAT ger en bedömning av grödans kväveupptag och visar på variationer inom ett fält genom att använda VI MSAVI (Engström et al., 2016). Ett högt värde tyder på ett högt klorofyll-innehåll och/eller en stor biomassa (Söderström et al., 2015).

En nackdel med satellitburna sensorer är att de påverkas av vatten i atmosfären och satellitburna sensorer burkar därför inte mäta reflektansen i SWIR-området. Beroende på den rumsliga upplösningen kan det vara svårt att mäta N-upptaget vid vändtegen.

3 Fältförsök

3.1 Bakgrund till försöket

3.1.1 Försökets upplägg

Fältförsöket är ett treårigt försök som ingår i ett forskningsprojekt som leds av Anne-Maj Gustavsson på SLU, Institutionen för norrländsk jordbruksvetenskap (NJV). Mätningar och resultat som använts i rapporten kommer från NJV och Yara med hjälp av Hushållningssällskapet som genomfört fältförsök på Rådde försöksstation i Sjuhäradsbygden. Delstudien som ingår i denna rapport är ett samarbete mellan Yara, Agroväst och SLU och är en del mot målet att kunna tillämpa N-sensor vid stödgödsling i vall.

I fältförsöket testas två faktorer: vallblandning med fyra olika fröblandningar och kvävegödsling med fem olika givor. Samtliga fröblandningar är insådda i korn år 2014. Det material som analyseras i rapporten kommer från ett försök av innehållande 36 försöksrutor fördelade på 12 olika led och 3-block. Fröblandningarna betecknas med A-D, där varje blandning och tillhörande giva presenteras i tabell 1.

Tabell 1. Försökleden

<i>Led</i>	<i>Kväve (kg/ha)</i>	<i>Fröblandning</i>
A1	0	Timotej, Eng. rajgräs, Rörsvingelhybrid
B1	0	Timotej, Eng. rajgräs, Rörsvingelhybrid + röd- och vitklöver
A2	150	Timotej, Eng. rajgräs, Rörsvingelhybrid
B2	75	Timotej, Eng. rajgräs, Rörsvingelhybrid + röd- och vitklöver
A3	225	Timotej, Eng. rajgräs, Rörsvingelhybrid
B3	150	Timotej, Eng. rajgräs, Rörsvingelhybrid + röd- och vitklöver
A4	300	Timotej, Eng. rajgräs, Rörsvingelhybrid
B4	225	Timotej, Eng. rajgräs, Rörsvingelhybrid + röd- och vitklöver
A5	375	Timotej, Eng. rajgräs, Rörsvingelhybrid
B5	300	Timotej, Eng. rajgräs, Rörsvingelhybrid + röd- och vitklöver
C5	375	Timotej, Eng. rajgräs, Rörsvingelhybrid Rajsvingel
D5	375	Timotej, Ängsvingel

I de 36 försöksrutorna gjordes sensormätningar med en passiv sensor (handburen N-sensor) som registrerar reflektans var tionde våglängd mellan 400-1000 nm. I varje ruta utfördes mätningar diagonalt in mot rutans mitt från vardera hörn för att efterlikna mätningar från en traktorburen sensor. Mätningarna utfördes den 4 juni, 10 juli och 24 augusti år 2015, före första-, andra- och tredjescörd.

3.1.2 Statistisk analys och hantering av data

Skördarna analyserades med avseende på grönmassa (kg/ha), ts (kg/ha), andel klöver och gräs (%), råproteinhalt (g/kg ts) i gräs och klöver samt proteinmängd (kg). Den totala råproteinhalten i blandvallarna erhöles genom att multiplicera andelen klöver och gräs med råproteinhalten av vardera.

Data från sensormätning sammanställdes till ett medelvärde från de fyra mätningarna i varje ruta och värdena för rutorna i samma led sammanställdes till ett gemensamt medelvärde för varje led ex A1, A2, A3 etcetera.

Enkel linjär regression

Medelvärdet för varje led användes sen i formler av fyra olika VI: NDVI, GNDVI, NIR/Red och NIR/Green. De våglängder som användes i VI var 550 nm för grönt ljus, 670 nm för rött ljus och 780 nm för NIR.

Sambanden mellan de fyra olika VI och biomassa, ts, råprotein och proteinmängd studerades med enkel linjär regression.

Multipel linjär regression

En Partial least square (PLS) analys sammanställdes med hyperspektral data mellan 400 och 900 nm. PLS-kalibrering är en multivariat linjär regressionsmetod där alla våglängder används för att undersöka samband med analysvärden. Vidare undersöktes om sambanden från PLS-kalibrering kunde användas som modeller för att förutsäga analysvärden genom validering.


Vid validering används vanligtvis ett oberoende dataset som inte ingår i skapandet av modellen. Eftersom endast ett försök undersöktes i rapporten fanns inte ett oberoende dataset att använda vid validering och därför användes valideringsmetoden *korsvalidering* istället. Vid korsvalidering hålls grupper eller enskilda datapunkter undan från kalibreringen för att se om resterande data kan förutsäga de undanhållna datapunkternas värde. I rapporten hölls ett prov undan i taget och samtliga valideringar utom ett i rapporten har gjorts med korsvalidering. Undantaget gäller i gräsvallarna där en modell utifrån biomassa i skörd 1 används för att prediktera biomassa i skörd 2.

4 Resultat fältförsök

4.1 Analysvärden – skörd och protein

Skördemängd

Figur 4 visar att med en ökad kvävetillförsel stiger skördemängden i ts. Vid låg gödning ger blandvallarna i försöket en större skörd, men med ökad mängd tillsatt kväve stiger skördemängden snabbt i gräsvall.




Figur 4. Skördens storlek i kg/ha beroende på kvävetillförsel från samtliga 3 skördar.

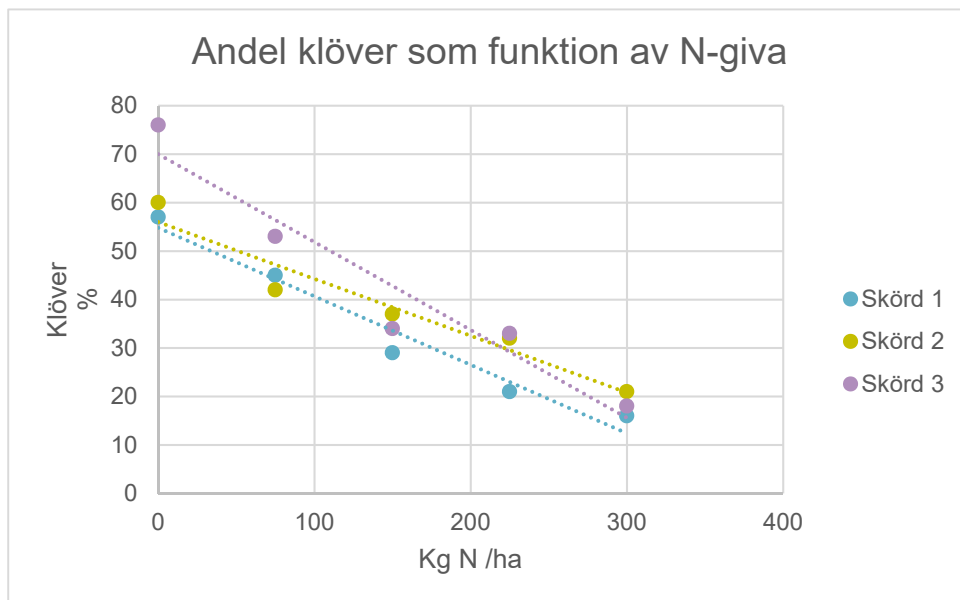
Proteininnehåll

Råproteinhalten i gräs- och blandvallarna skiljer sig åt på så vis att råproteinhalten stiger med ökad kvävetillförsel i gräsvallarna medan den är lätt u-formad i blandvallarna (figur 5).

Andelen klöver i blandvallarna minskar med en ökad kvävetillförsel vilket visas i figur 6.



Figur 6. Skördens råproteinhalt (g/kg ts) i alla tre skördar beroende på kvävetillförsel.



Figur 5. Andel klöver i blandvallarna vid de tre skördarna.

4.2 VI

Korrelation mellan VI (NDVI, GNDVI, NIR/Red och NIR/Green) och analysvärden (biomassa, ts, råproteinhalt och proteinmängd) beskrivs i tabell 2. I tabellen kan observeras att VI innehållande gröna våglängder korrelerar bäst med samtliga analysvärden och att skillnaden mellan GNDVI och NIR/Green är liten.

Tabell 2. Sammanställning av hur väl VI förklarar (r^2) variationen i biomassa, ts, råprotein och proteinmängd. Fetmarkerade värden representerar det högsta uppmätta värdet inom varje analys.

VI	Samtliga vall- blandningar	Gräsvall Led A, C, D	Gräsvall Led A	Blandvall Led B
Biomassa (kg/ha)				
NDVI	0,15	0,18	0,23	0,08
GNDVI	0,43	0,54	0,58	0,09
NIR/Red	0,12	0,14	0,20	0,07
NIR/Green	0,45	0,54	0,60	0,09
Torrsubstans (kg/ha)				
NDVI	0,14	0,16	0,22	0,07
GNDVI	0,40	0,46	0,54	0,17
NIR/Red	0,09	0,10	0,17	0,05
NIR/Green	0,37	0,44	0,55	0,16
Råproteinhalt (g/kg ts)				
NDVI	0,09	0,21	0,16	0,08
GNDVI	0,32	0,62	0,53	0,15
NIR/Red	0,10	0,24	0,17	0,04
NIR/Green	0,45	0,67	0,58	0,14
Proteinmängd (kg)				
NDVI	0,12	0,16	0,16	0,04
GNDVI	0,46	0,59	0,56	0,09
NIR/Red	0,1	0,13	0,14	0,04
NIR/Green	0,32	0,60	0,59	0,08

Då gräsvall delas upp ytterligare i led A blir korrelationen mellan biomassa, ts och VI något starkare och för råprotein, proteinmängd något svagare. Resultaten i tabell 2 visar också att skillnaden i korrelationen mellan VI och biomassa samt VI och ts inte är särskilt stor. Detsamma gäller för korrelationen mellan VI och råprotein samt VI och proteinmängd.

Sambandet mellan VI och analysvärden då alla vallblandningar undersöks samtidigt varierar med som högst r^2 -värden mellan 0,4 och 0,46 för de olika analyserna. Då vallblandningarna delas upp mellan gräsvallarna och blandvallarna ökar

korrelationen något i gräsvallarna men sjunker i blandvallarna. I blandvallarna är korrelationen generellt låg, som högst ett r^2 -värde på 0,17.

Då gräsvall delas upp ytterligare i led A blir korrelationen mellan biomassa, ts och VI något starkare och för råprotein, proteinmängd något svagare.

4.3 Hyperspektral data

4.3.1 Kalibrering

Generellt blev korrelationerna starkare mellan sensormätningar och analyser när hyperspektral data användes jämfört med när VI användes. Ett undantag fanns och gällde råproteinhalt i blandvall och då samtliga vallblandningar användes, se markerad * i tabell 3.

Tabell 3. Samanställning av r^2 -värden från kalibrering (Kal) och validering (Val) för biomassa, torrsubstans, proteinhalt och proteinmängd. * markerar värden visar r^2 -värden som är lägre än r^2 -värden i den enkla linjär regression med VI.

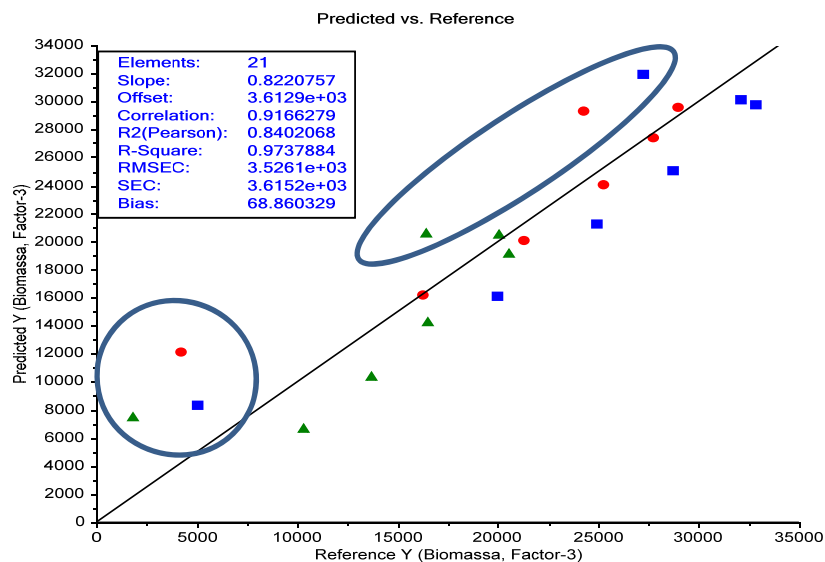
<i>PLS</i>	<i>Samtliga vall- blandningar</i>	<i>Gräsvall Led A, C, D</i>	<i>Gräsvall Led A</i>	<i>Blandvall Led B</i>
Biomassa (kg/ha)				
<i>Kal</i>	0,74	0,84	0,88	0,91
<i>Val</i>	0,55	0,66	0,71	0,17
Torrsubstans (kg/ha)				
<i>Kal</i>	0,48	0,54	0,62	0,21
<i>Val</i>	0,12	0,23	0,32	0,39
Råproteinhalt (g/kg ts)				
<i>Kal</i>	0,34*	0,96	-	0,01*
<i>Val</i>	0,29	0,93	-	0,15
Proteinmängd (kg)				
<i>Kal</i>	0,78	0,91	-	0,82
<i>Val</i>	0,67	0,77	-	0,07

Resultat från sambandet mellan hyperspektral data och biomassa, torrsubstans, råproteinhalt och proteinmängd i PLS-analyserna presenteras i tabell 3.

Sett till kalibreringsresultaten i tabell 3 visas att då samtliga vallblandningar undersöktes samtidigt var korrelationen relativt god för samtliga analyser, men bäst för proteinmängd och biomassa.

När vallblandningarna delades upp mellan gräsvallar och blandvallar ökade korrelationen i gräsvallarna, men endast för biomassa och proteinmängd i blandvallarna. I gräsvallarna var sambandet mellan råproteinhalt och sensormätning det högst uppmätta, r^2 -värde på 0,96, men även sambandet mellan sensormätning och biomassa samt sensormätning och proteinmängd var högt.

Sambandet ökade ytterligare för biomassa och ts i gräsvallarna då led A separerades från de övriga gräsvallarna och i tabell 3 visas att oavsett vallblandning, korrelerade sensormätningar och biomassa bättre än sensormätningar och ts. I figur 7 visas sambandet för biomassa i gräsvallarna och i figuren går det att se att de olika skördarna följer varandra åt samt att 0 kväve-givorna skiljer sig från de andra mätpunkterna. Led D som har en annorlunda gräsblandning skiljer sig också från Led A.




Figur 7. Beräknad mot uppmätt biomassa för PLS-kalibrering med hyperspektral data i gräsvallarna. Olika färger beskriver olika skördar och den nedre cirkeln ringar in 0 N-givorna. Den övre cirkeln ringar in led D.

4.3.2 Validering

Tabell 3 visar sambandet mellan hyperspektral data och analysvärden då de används i modeller för att bestämma biomassa, torrsubstans, råproteinhalt och proteinmängd.

Modeller då alla vallblandningar ingår


Då alla vallblandningar undersöktes samtidigt var modellen för att bestämma proteinmängden bäst. Även modellen för att bestämma biomassa var god medan modellen för att bestämma ts och råproteinhalten var något sämre. Figur 8 visar sambandet mellan sensormätning och proteinmängd utifrån kalibrering och hur väl en modell stämmer överens med det sambandet utifrån validering.



Figur 8. Resultat från proteinmängdsbestämning med PLS-modell. Beräknad mot uppmätt proteinmängd i samtliga vallblandningar från alla skördar. Figuren visar både kalibrering och validering

Modeller i gräs- och blandvallarna


Då vallblandningarna delades upp mellan gräs- och blandvallar ökade r^2 för samtliga analysvärden i gräsvallarna, men endast för ts i blandvallarna. Generellt är r^2 -värdet lågt i blandvallarna och det högsta uppmätta r^2 -värdet är 0,39. I gräsvallarna var den bästa modellen för råproteinhalt där r^2 -värdet uppgick till 0,93 (figur 9).




Figur 9. Resultat från proteinhaltsbestämning med PLS-modell Beräknad mot uppmät råproteinhalt i gräsvall från alla skördar. Figuren visar både kalibrering och validering

Modeller för att bestämma biomassa och ts i enbart led A

I gräsvallarna undersöktes modellen för att bestämma biomassa och ts noggrannare genom att separera led A från C och D och genom att titta på första skörden för sig. Resultatet blev att korrelationen ökade ytterligare något för både biomassa och ts och visas i figur 10 och 11. I figuren visas även att modellen är sämre i blandvallarna än gräsvallarna.




Figur 10. Predikterad mot uppmätt biomassa för korsvaliderade modeller gjorda med alla vallblandningar, gräsvallblandningar, led A och blandvallar.



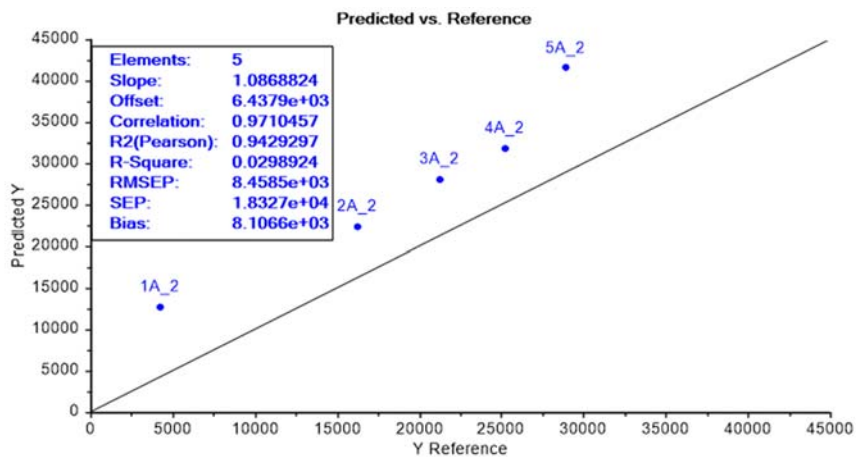
Figur 11. Predikterad mot uppmätt ts för korsvaliderade modeller gjorda med alla vallblandningar, gräsvallblandningar, led A och blandvallar.

Korsvalideringen av en modell för bestämning av biomassa gjord på bara första skörden i led A resulterade i högre r^2 -värde jämfört när alla skördar ingick i modellen, från 0,71 till 0,82 (figur 12). Även när modellen gjord på första skörden

i led A användes för att bestämma biomassa i skörd två blev r^2 -värdet högt, 0,94, men med ett systematiskt fel (bias) på 8000 kg/ha, vilket kan ses i figur 13.



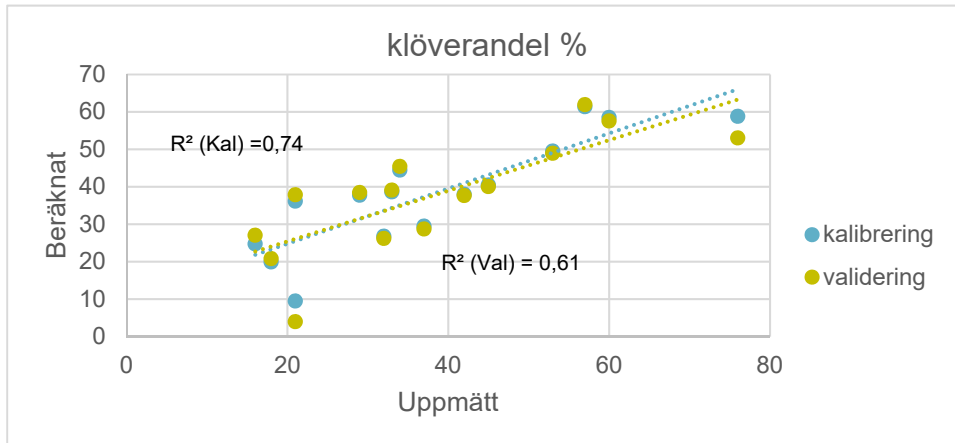
Figur 12. Beräknad mot uppmätt biomassa för PLS-kalibrering med hyperspektral data i gräsvallarna. Prediktioner av skörd 1 är skapade utifrån en modell av skörd 1.



Figur 13. Beräknad mot uppmätt biomassa för PLS-kalibrering med hyperspektral data i gräsvallarna. Prediktioner av skörd 2 är skapade utifrån en modell av skörd 1 och alltså inte korsvalidering.

Modell för att bestämma klöverandel i blandvallar

Sambandet mellan klöverandelen och hyperspektral data i blandvallarna var bra, med ett r^2 -värdet för kalibreringen på 0,74 (figur 14). Korsvalidering av modellen resulterade i ett r^2 -värde på 0,61.



Figur 14. Beräknad mot uppmätt klöverandel i alla skördar.

5 Diskussion

5.1 Diskussion av resultat

Ett av de problem som uppstår vid tillämpning av sensormätning i vall är att vallen utformas beroende på varje gårds egna produktionsmål och förutsättningar. Vallen består dessutom av flera arter vilka väljs efter dessa mål och den stora variationen av vallar ställer krav på att modellen för att använda sensormätning som analysredskap är flexibel. I praktiken önskas ett analysredskap som kan ge en prognos av innehållet i grödan och därmed uppskatta näringsbehovet.

I försöket på Rådde ingick arterna Timotej, Engelskt rajgräs, Rörsvingelhybrid, Rajsvingel, Ängsvingel samt röd- och vitklöver. Förutom röd och vitklöver, är samtliga monokotyledoner och tillhör stråsädesfamiljen med en liknande cellstruktur. Att tillämpa optisk sensorteknik i rena gräsvallar borde därför inte vara omöjligt eftersom tekniken redan finns utvecklad i annan stråsåd.

Röd och vitklöver är istället dikotyledoner och skiljer sig inte bara i cellstruktur utan också till att de kan fixera sitt eget kväve i symbios med bakterier. Beroende på kvävetillgång varierar därför klöverns konkurrensförmåga gentemot gräset och därför också andelen klöver.

I resultatdelen visas att andelen klöver i fältförsöket minskar med en ökad kvävegödsling, men att ts ökar och råproteinhalten är relativt konstant. Det beror på att gräsets proteininnehåll och biomassa ökar med en ökad kvävetillförsel. För att verkligen ta vara på klöverns kvävefixerande förmåga tror jag därför att det är viktigt att ha kännedom om andel klöver i fältet.

Vidare i resultatdelen undersöktes sambandet mellan analysvärden från biomassa, ts, råproteinhalt och proteinmängd med uppmätt sensormätning med hjälp av två metoder, VI (med linjär regression) och hyperspektraldata (med PLS). Varför just dessa områden analyserades var för att hela växten utgör skörden i en vall

och därför är biomassan intressant. En stor del är dock vatten och därför undersöktes även samband mellan sensormätning och torrsubstans också.

Råproteinhalten och proteinmängden är intressant att analysera eftersom klorofyll och proteiner är starkt kopplade till kvävekoncentrationen i bladen. En god korrelation mellan sensormätning och proteinhalt innebär därför en möjlighet till optimering av kvävegödsling. En optimering av kvävegödslingen skulle i sin tur minska risken för näringsläckage och ett bättre utnyttjande av grödans fulla potential.

I resultatdelen konstaterades bland annat att linjär regression med VI generellt gav lägre korrelation än PLS av hyperspektral data samt att VI utformade av gröna våglängder gav bättre korrelation än röda. Det var även liten skillnad mellan GNDVI och NIR/Green. Att användning av hyperspektral data gav en starkare korrelation med växtens egenskaper har bland annat förklarats i en tidigare studie av Foster, Kakani & Mosali (2016). I den predikteras N-koncentration och biomassan i perenna gräs med vegetationsindex NDVI och hyperspektral data i PLS. Deras resultat visade på liknande vis att PLS av hyperspektral data gav ett bättre samband än linjär regression av VI. Att hyperspektral data ger ett bättre samband visar på att det finns information av vikt som fitreras bort i VI.

Min teori till varför de gröna våglängderna gav starkare korrelation än de röda är att LAI var högt innan första skörden och att mättnadsgraden för NDVI var nådd. I försöket fanns både blad, strågräs- och klöverarter med. Blad- och strågräs uppträder olika i utvecklingshastighet trots att båda är monokotyledoner (Fogelfors, 2015). Bladgräs breder ut sig snabbare och bildar tuvor medan strågräs sträcker på sig och har fler bladnivåer. En vall med flera arter innebär därför fler parametrar som påverkar hur LAI utvecklas. Det har visat sig i studier att höga klorofyllkoncentrationer och LAI över 3-4 svarat bättre på våglängder från det gröna spektrumet. (Shanahan et al., 2001; Pettersson, 2006) och min teori är därför att LAI steg fort i vallarna och att det kan vara en del till förklaringen till varför VI med gröna våglängder (GNDVI och NIR/Green) gav bättre korrelation jämfört med röda våglängder.

Att dela upp alla vallblandningar mellan gräs och blandvall gjorde att sambandet mellan sensormätning och analysvärden för både VI och den hyperspektrala datan ökade i gräsvall, se tabell 2 och 3. Det beror troligtvis på att artvariationen inom gräsvall minskade samt att skillnaden i reflektansmönster mellan monokotyledoner och dikotyledoner är större än mellan olika arter av gräs och eftersom klöver är kvävefixerande (Guyot, 1990).

På liknande vis ökade korrelationen för biomassa och ts då led A separerades från de övriga gräsvallarna. Varför korrelationen inte ökade mellan VI och råproteinhalten eller proteinmängd då led A separerades kan bero på att proteinmängden beror mycket på klorofyllkoncentrationen och att klorofyllkoncentrationen inte

skiljer mycket åt mellan olika gräs. Biomassa mäts främst genom skillnader i NIR och kanske är de olika gräsarternas cellstruktur mer olika. Vidare var korrelationen mellan sensormätning och proteininnehåll bland de starkaste. Det är intressant eftersom det var vad som kan förväntas. Sensorerna läser ju av klorofyllinnehållet och därmed proteininnehållet.

I ett liknande försök i vall av Börjesson et al. (2002) visade resultatet att god potential fanns i att utveckla sensorer som prognosmetoder för vall. Deras resultat visade också att modellen för att prediktera ts-avkastning var väldigt bra och att goda möjligheter fanns för prediktion av råproteinhalt.

För blandvallarna var korrelationen för proteinhalt och proteinmängd låga. Det kan bero på att andelen klöver minskar med ökad kvävegiva eller att råproteinhalten inte ökade linjärt med ökad kvävemängd som för gräsvallarna. I resultatdelen undersöktes sambandet mellan sensormätning och klöverandelen med r^2 -värde för kalibreringen på 0,74 och för valideringen 0,61, vilket tyder på att samband finns mellan sensormätning och klöverandelen. Sensorn kan alltså läsa av klöverandelen i försöket. Att klöverandelen kunde läsas av i försöket bådär gott för att det även går att läsa av klöverandelen i andra blandvallsförsök. Givan skulle då kunna anpassas efter klöverandelen där en ökad kvävegiva generellt missgynnar klöverandelen och får den att minska. I teorin skulle klöverandelen därför gå att styra i blandvallar.

Framtida behov

För att nå målet med att använda sensormätning som ett analysredskap i vall behöver fler VI undersökas. Eftersom min uppsats endast tog upp fyra vegetationsindex, också med fokus på ungefär samma sak, tror jag det kan vara intressant att titta på andra vegetationsindex i framtiden. I sökandet efter litteratur påträffade jag jag vid några tillfällen indexet red inflection point. Jag tror att det kan vara något att fortsätta undersöka. Jag stötte även på forskning som tittar på sensormätning tillsammans med radar för att bättre kunna urskilja andelen klöver i vallen och på så vis hitta samband med skördemängd och skörde kvalitet. Eftersom sambanden var lägst i blandvallarna och eftersom klöverandelen troligen är bidragande till att sambanden blev låga tror jag det kan vara intressant att med hjälp av sensorer kartlägga andelen klöver.

5.2 Slutsats

Trots att hyperspektral data generellt gav en starkare korrelation än VI kan användning av index vara mer kommersiellt praktiskt eftersom det innebär en mindre datamängd att hantera. Det är också viktigt att komma ihåg att endast fyra index

togs upp i arbetet och att det finns behov av att undersöka fler för att kunna dra några konkreta slutsatser om resultatet. De resultat som presenteras är en del av ett större arbete, och mer kommer att gå att säga när hela studien är färdig. Men slutsatser från det enskilda försöket kan ändå dras. Index innehållande gröna våglängder gav bättre korrelation än röda. Proteinhalten och proteinmängden i gräsvallarna gick att läsa av med hjälp av optisk sensor och det gick att förutsäga proteinhalten med en modell utformad från sambandet. Det gick också att dra slutsatsen att gräsvall utan klöver läses av bättre med optisk sensor än gräsvall med klöver i.

Referenslista

- Bannari, A., Morin, D., Bonn, F. (1995). A Review of Vegetation Indices. *Remote Sensing Reviews*, 13, 95-120
- Biewer S., Erasmi S., Fricke T. och Wachendorf M. (2009) Prediction of yield and the contribution of legumes in legume-grass mixtures using field spectrometry. *Precision Agriculture* 10, 128–144.
- Börjesson, Nyberg, Stenberg och Wetterlind (2002) *Handburen hydro sensor i vall – prediktering av torrsubstansavkastning och kvalitetsegenskaper*. Skara: Precisionsodling Sverige (Teknisk rapport 2) Tillgänglig: <http://pub.epsilon.slu.se/4418/>
- Börjesson, T. & Söderström, M. (2003). Prediction of protein content in cereals using canopy reflectance. I: Stafford, J. & Werner, A. (red.) *Precision Agriculture*, ss. 89-282.
- Börling, K. (red.), Albertsson, B. Kvarnmo, P. Listh, U. Malgeryd, J. Stenberg, M. (2016). *Rekommendationer för gödsling och kalkning 2017*. Jordbruksverket (Jordbruksinformation 24). Tillgänglig: <http://webbutiken.jordbruksverket.se/sv/artiklar/jo1624.html>
- Campbell, N., Reece, J., Urry, L., Cain, M., Wasserman, S., Minorsky, P & Jackson, R. (2015.) Photosynthetic processes. I: Wilbur, B. (red). *Biology – A global approach*. Edinburgh Gate:Pearson Education Limited, ss. 266-267
- Eastman, R. (2001) *Guide to GIS and Image Processing volume 1*. Worcester USA: Clark University.
- Engström, J., Jonsson, A., Gilbertsson, M., Johnsson, B., Höller, J., Gustafsson, M., Segerborg-Fick, A. & Rydberg, A. (2016). *Effektivisering av jordbruket med IKT – Förstudie del 1*. Uppsala: JTI – Institutet för jordbruks- och miljöteknik. Tillgänglig: <http://www.jordbruksverket.se/download/18.44d1a6d715b53cf7b563214a/1491828455833/U-rapport+Effektivisering+av+jordbruket+med+ICT+161230+finalref.pdf>
- Evans, J. (1989) Photosynthesis and nitrogen relationships in leaves of C3 plants. *Oecologia* 78, 9-19.

- Fogelfors, H. (2015). Grödor, Mark. I: Fogelfors, H. (red), *Vår mat – odling av åker- och trädgårdsgrödor*. Upplaga 1. Lund: studentlitteratur.
- Foster, A. Kakani, V. & Mosali, J. (2016) Estimation of bioenergy crop yield and N status by hyperspectral canopy reflectance and partial least square regression. *Precision Agriculture*, 18, 192-209.
- Guyot, G 1990. Optical properties of vegetation canopies. I: Stevens. M.D., Clark. J.A (red) *Applications of Remote Sensing in Agriculture*. Kent UK. Butterworths, ss. 19-43
- Heege, H. & Thiessen, E. (2013). Sensing of Crop Properties. I: Heege, H. *Precision in Crop Farming*. Dordecht Heidelberg, New York, London. Springer, ss. 103- 133.
- Jordbruksverket (u.å). Vall – vår största gröda. Tillgänglig: <http://www.jordbruksverket.se/ammesomraden/odling/jordbruksgrodor/vall.4.23f3563314184096e0d7c75.html> [2017-06-14]
- Larsson, R. (2011). *Grödreflektans och bildanalys för bestämning av biomassa i fältförsök*. Sverigeslantbruksuniversitet. Institutionen mark och miljö (Examensarbeten, 2011:10).
- Parsons, D. (2017) Opportunities for development of forage systems in Sweden – impressions from a newcomer. I: Nilsson-Linde, N. & Bernes, G. (red.) (2017). *Vallkonferens 2017* (ss 7-10). Uppsala, Sverige 7-8 februari. Tillgänglig: <http://pub.epsilon.slu.se/14045/>.
- Pettersson, C. G., Söderström, M. & Eckersten, H. 2006. Canopy reflectance, thermal stress, and apparent soil electrical conductivity as predictors of within-field variability in grain yield and grain protein of malting barley. *Precision Agriculture*, 7, 343-359
- Shanahan, J. F., Schepers, J. S., Francis, D. D., Varvel, G. E., Wilhelm, W. W., Tringe, J. M., Schlemmer, M. R. & Major, D. J. (2001). Use of remotesensing imagery to estimate corn grain yield. *Agronomy Journal*, 93, 583-589.
- Swensson, C & svensk mjölk. (2011). *Råd om kvävegödsling till vällen – gårdens förutsättningar bestämmer vallens kvävegiva*. Greppa näringen (Greppa näringens praktiska råd nr 6 upplaga 3). Tillgänglig: http://www.greppa.nu/download/18.37e9ac46144f41921cd1a71b/1402315666284/Praktiska_r%C3%A5d_Nr_6_Vall_kv%C3%A4veg%C3%B6dsling.pdf
- Söderström, M. Stadig, H. Nissen, K. & Piikki, K. (2015) *CropSAT: kväverekommendationer och grödstatuskartering inom fält genom en kombination av satellitdata och N-sensorer*. Skara: Institutionen för mark och miljö precisionsodling och pedometri, Teknisk Rapport nr 36.
- Yara (u.å). *Så här fungerar Yara N-Sensor*. Tillgänglig: <http://www.yara.se/vaxtnaring/hjalpmedel-och-garantier/yara-n-sensor/sa-har-fungerar-yara-n-sensor/> [2017-05-23].
- Ågren, J., Eklund, L., Olsson, H., Harrie, L. & Klang, D. (2013). Insamling av geografiska data. I Harrie, L. (Red) (2013.), *Geografisk informationsbehandling – teori, metoder och tillämpningar*. Lund: Studentlitteratur AB, ss. 115-126

Tack

Tack till Sofia Kämpe vid Agroväst som är ansvarig för studien och som funnits tillgänglig för frågor och tack till Anne-Maj Gustafsson vid NJV som är ansvarig för försöket, där jag fått tillgång till ett års data, och funnits tillgänglig vid eventuella frågor. Tack även till Yara som tillhandahållit N-sensormätningarna.

Stort tack till min handledare Johanna Wetterlind som varit en klippa i arbetet och som med orubbat tålamod hjälpt mig med skapandet av PLS-analyser och outtröttligt svarat på alla diverse frågor.