Tabell 3. *Modelling efficiency (ME) och Mean absolute error (MAE) för prediktioner av ekonomiskt optimal kvävegiva. Prediktionerna har gjorts med Boosted regression trees (BRT), multiple adaptive regression splines (MARSplines), k nearest neighbour prediction (kNN) och artificiella neurala nätverk (ANN) för sex olika prediktordataset (se tabell 2). Värden som är bättre än för 2012 års riktgivor markeras med röd fet stil.*

Metod	**Dataset**	**ME (%)**	**MAE (kg / ha)**
MARSplines	1	**28**	24
MARSplines	2	**72**	**15**
MARSplines	3	< 0	37
MARSplines	4	< 0	47
MARSplines	5	5	27
MARSplines	6	< 0	34
ANN	1	**38**	**22**
ANN	2	**65**	**17**
ANN	3	< 0	29
ANN	4	< 0	31
ANN	5	6	25
ANN	6	-9	29
kNN	1	**23**	24
kNN	2	**50**	**20**
kNN	3	< 0	28
kNN	4	< 0	26
kNN	5	< 0	28
kNN	6	< 0	26
BRT	1	9	26
BRT	2	**49**	**19**
BRT	3	< 0	27
BRT	4	< 0	31
BRT	5	21	24
BRT	6	2	27

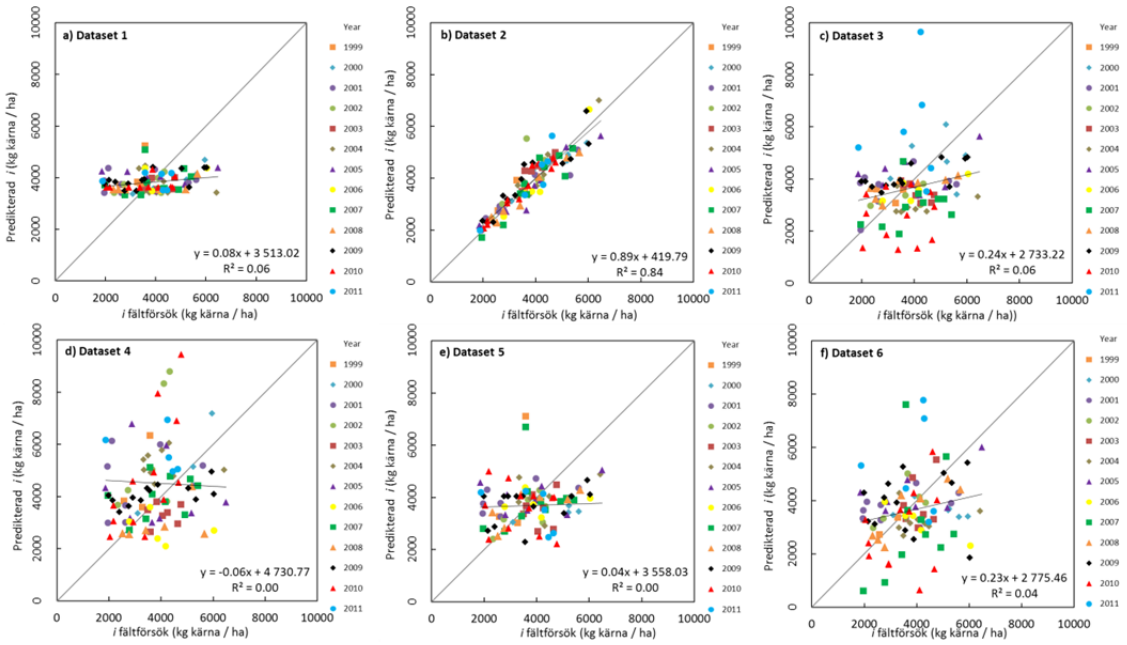

Figur 19. *Parameter i (se ekvation 1) predikterad med MARSplines plottad mot värden bestämda i fältförsök. Dataset a-f beskrivs i tabell 2. I figur d finns två outliers som ligger utanför skalan på y-axeln.*

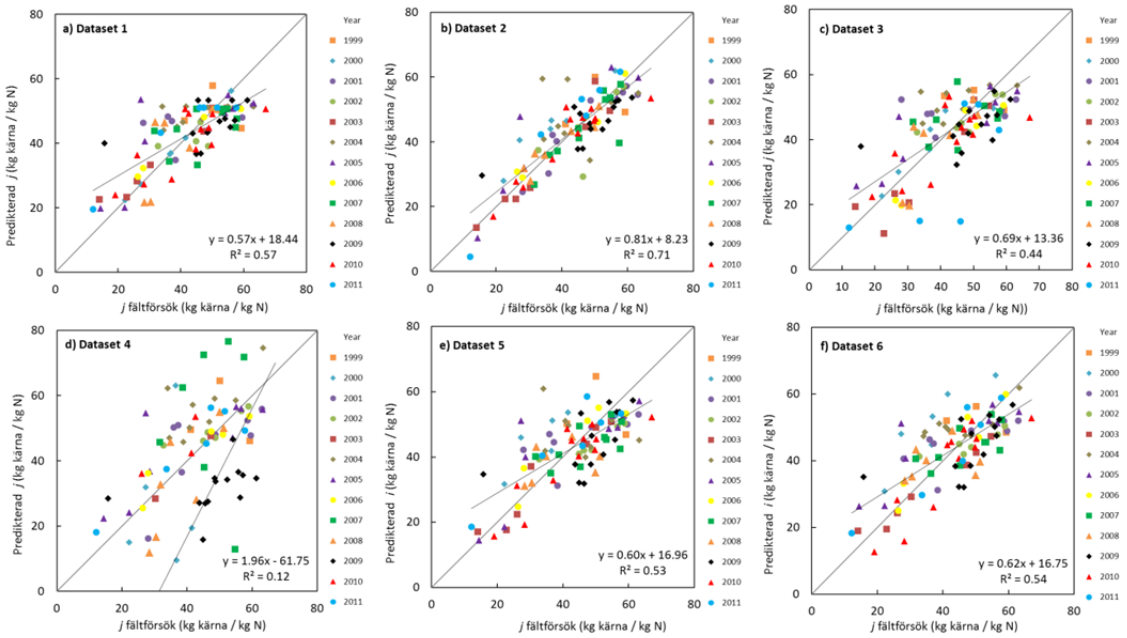

Figur 20. *Parameter j (se ekvation 1) predikterad med MARSplines plottad mot värden bestämda i fältförsök. Dataset a-f beskrivs i tabell 2. I figur d finns flera outliers utanför y-axelns intervall (3 försök 2003, 1 försök 2007 och 8 försök 2010).*

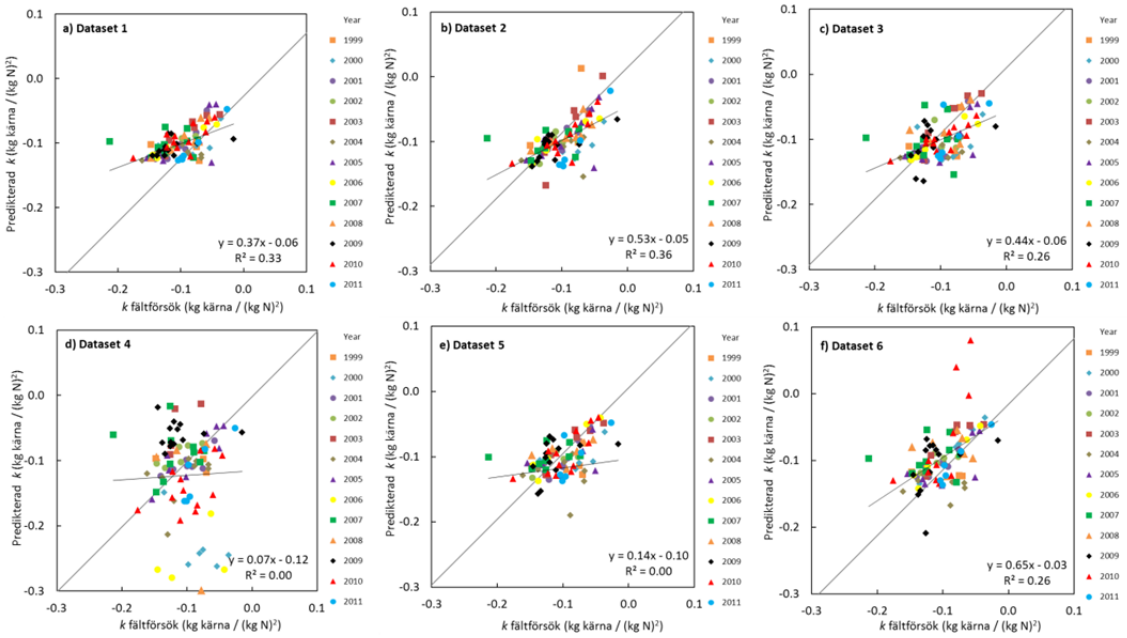

Figur 21. *Parameter k (se ekvation 1) predikterad med MARSplines plottad mot värden bestämda i fältförsök. Dataset a-f beskrivs i tabell 2. I figur d finns flera outliers utanför y-axelns intervall (3 försök 2003, 1 försök 2006 och 3 försök 2008 hade negativa predikterade j-värden).*

Tabell 4*. Modelling efficiency (ME) och Mean absolute error (MAE) för prediktioner av produktionsfunktionernas parameterar (ekvation 1) Prediktionerna har gjorts med multiple adaptive regression splines (MARSplines) för sex olika prediktordataset (se tabell 2). Tabellen fortsätter på nästa sida.*

Dataset	Parameter	ME (%)	MAE (enheter)
1	*i*	5	925
2	*i*	84	351
3	*i*	< 0	1122
4	*i*	< 0	1714
5	*i*	< 0	1043
6	*i*	< 0	1175
1	*j*	57	7
2	*j*	70	5
3	*j*	30	8
4	*j*	< 0	33
5	*j*	52	7
6	*j*	53	7

Tabell 4. *Fortsättning från föregående sida.*

Dataset	Parameter	ME (%)	MAE (enheter)
1	*k*	33	0.022
2	*k*	28	0.022
3	*k*	15	0.026
4	*k*	< 0	0.081
5	*k*	< 0	0.041
6	*k*	< 0	0.028

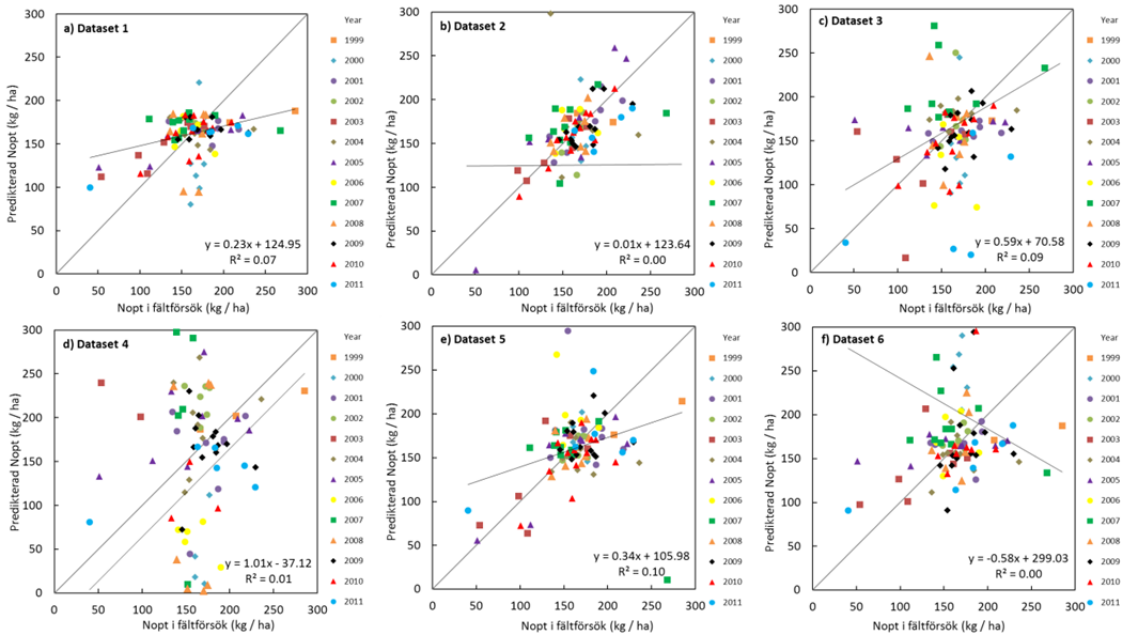

Figur 22. *Ekonomiskt optimal kvävegiva (Nopt) beräknad från predikterade värden av j och k (figur 20-21) plottad mot verklig Nopt i fältförsök. Dataset a-f beskrivs i tabell 2. I figur d finns 22 outliers utanför y-axelns intervall.*

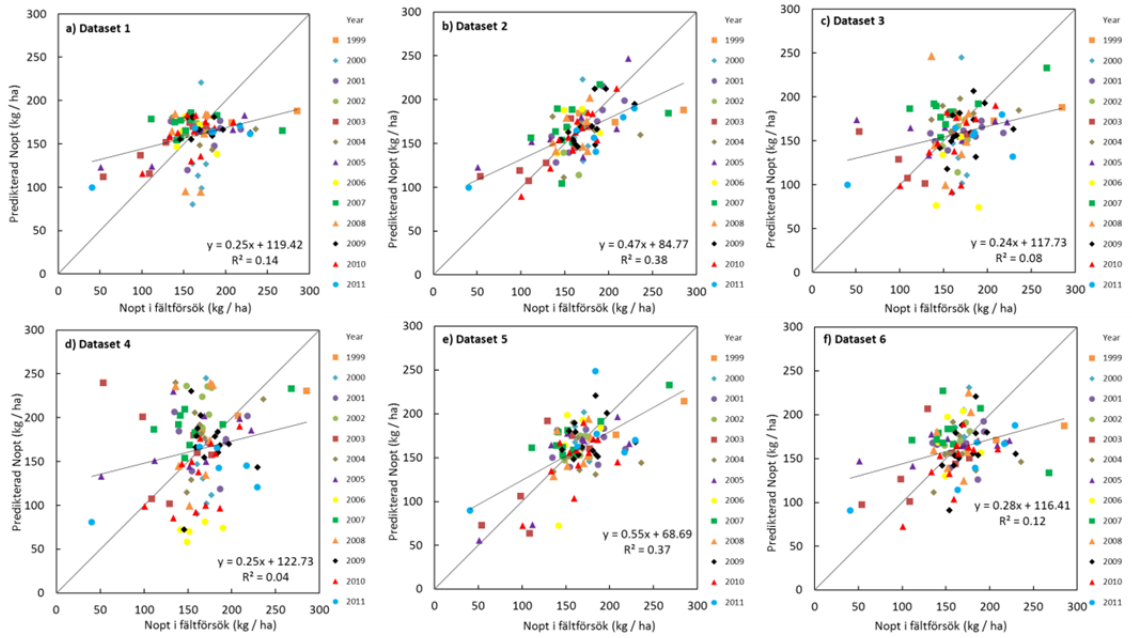

Figur 23. *Samma resultat som i figur 22 men med begränsningen att Nopt som är större än 250 kg / ha eller mindre än 50 kg / ha har ersatts med 2012 års riktgivor.*

Tabell 5. *Modelling efficiency (ME) och Mean absolute error (MAE) ekonomiskt optimal kväevegiva (Nopt) som beräknats predikterade parametrar. De sex olika prediktordataset redovisas i tabell 2. Värden som är bättre än för 2012 års riktgivor markeras med röd fet stil.*

Dataset	Parameter	ME (%)	MAE (kg / ha)
1	Nopt	< 0	29
2	Nopt	< 0	59
3	Nopt	< 0	44
4	Nopt	< 0	190
5	Nopt	< 0	28
6	Nopt	< 0	83
1	Nopt (begränsad)	4	28
2	Nopt (begränsad)	**38**	**22**
3	Nopt (begränsad)	< 0	30
4	Nopt (begränsad)	< 0	40
5	Nopt (begränsad)	**29**	**23**
6	Nopt (begränsad)	< 0	29

Att kombinera olika modellberäkningar

Alla modellberäkningar blir mer eller mindre fel. Felbilden skiljer sig mellan olika modeller, en modell kanske huvudsakligen överskattar låga värden medan en annan framför allt underskattar höga värden. Ibland kan det därför fungera bra att kombinera flera predikterade värden. För parametrarna *j* och *k* har vi testat om resultatet blir bättre genom att man tar ett medelvärde av flera olika modellberäkningar. Resultaten visas i figur 24-25 samt i tabell 6. Denna efterbehandling gav dock enbart en marginell förbättring av resultatet i ett av tolv fall och utreds inte vidare.

Tabell 6. *Resultat av att kombinera resultat från flera modeller för prediktion av produktionsfunktionens parametrar j och k. ME= modelling efficiency (modellens förklaringsgrad), MAE = mean absolute error (medelfel). Resultat som är bättre än samtliga ingående prediktioner är markerade med rött.*

Dataset	**Parameter**	**ME (%)**	**MAE (enheter)**
1 och 3	*j*	54	7
1, 3 och 5	*j*	59	7
1och 4	*j*	<0	19
1 och 5	*j*	54	7
3 och 5	*j*	**54**	7
alla	*j*	-34	10
1 och 3	*k*	31	0.023
1, 3 och 5	*k*	<0	0.028
1och 4	*k*	<0	0.049
1 och 5	*k*	<0	0.030
3 och 5	*k*	<0	0.031
alla	*k*	<0	0.032

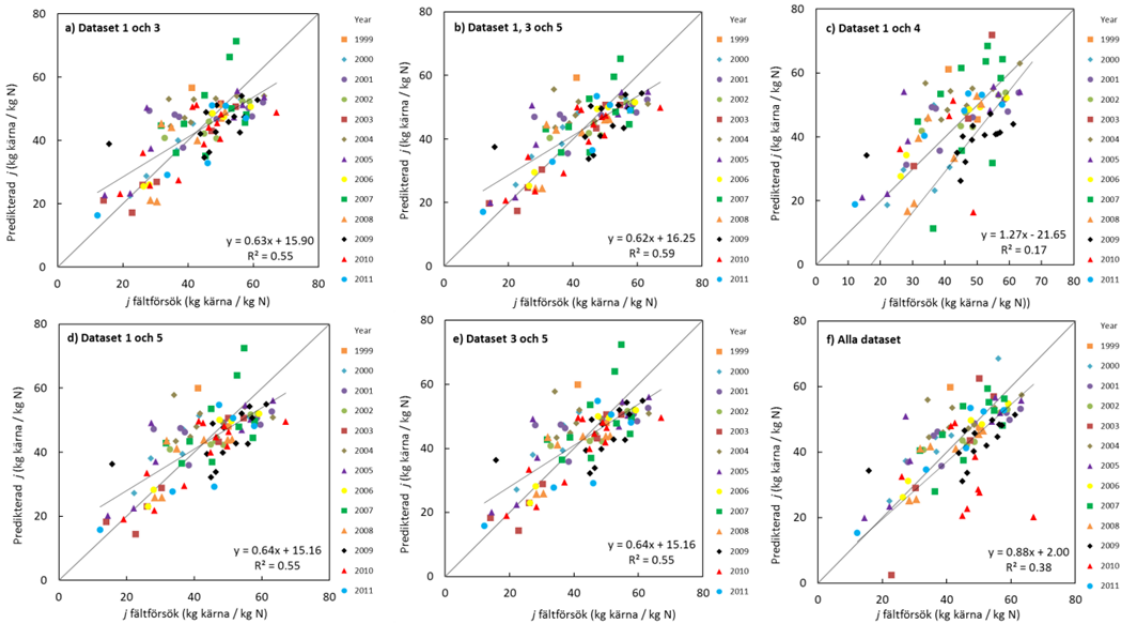

Figur 24. *Resultat av att kombinera resultat från flera modeller. Medelvärden av beräknade värden för j plottade mot j bestämd i fältförsök. De olika dataseten presenteras i tabell 2 . I figur c finns 13 outliers utanför y-axelns intervall.*

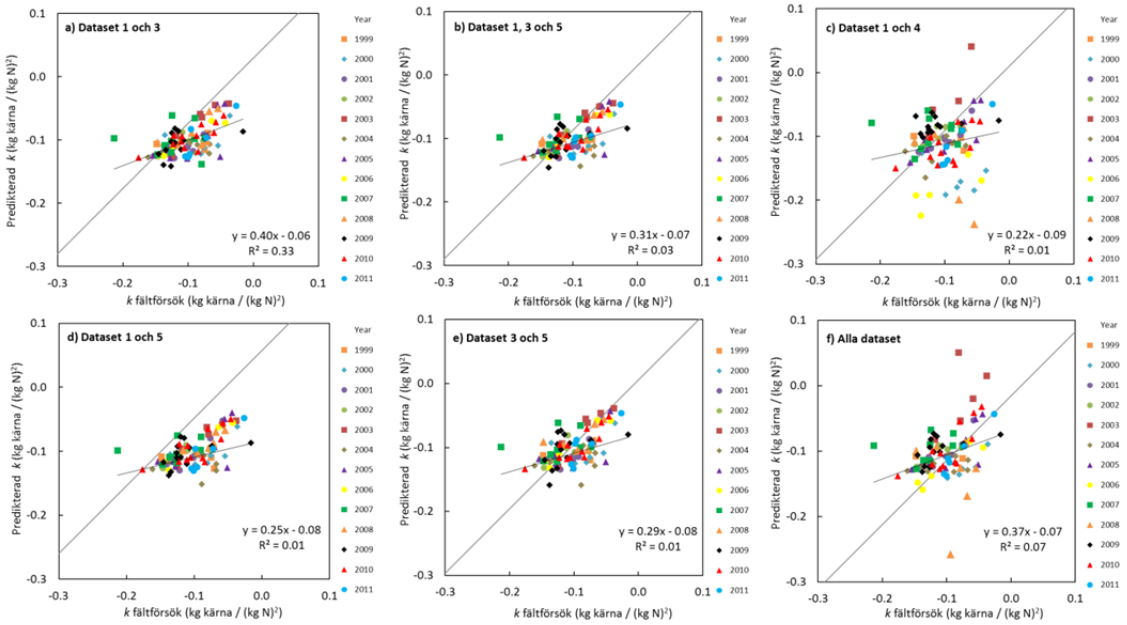

Figur 25. *Resultat av att kombinera resultat från flera modeller. Medelvärden av beräknade värden för k plottade mot k bestämd i fältförsök. De olika dataseten presenteras i tabell 2. I figur c finns 2 outliers utanför y-axelns intervall.*

Att utgå från dagens riktlinjer i modellberäkningarna

Modeller där kväveskörd i nollrutor ingår som prediktor (se tabell 3 samt figur 15-18 b) fungerar bäst men jämfört med övriga modeller står sig dagens riktlinjer för kvävegödsling väl. Ett tänkbart angreppssätt i modellberäkningarna är att utgå från dessa riktlinjer och se om de kan bli mer träffsäkra genom att man lägger till information om väder, mark och lokalisering. Jordbruksverkets rekommendationer lades därför till som prediktor till vart och ett av de sex dataseten i tabell 2. Strategin visade sig dock inte vara framgångsrik. För samtliga dataset blev resultatet sämre (med avseende på medelfel) när dagens riktlinjer lades till som prediktor (tabell 7, jämför med MARSplines-prediktionerna i tabell 3).

Tabell 7. *Utvärdering av prediktioner av ekonomisk optimal kvävegiva för sex olika uppsättningar av prediktorer (se tabell 2). Till samtliga dataset har 2012 års riktlinjer för kvävegödsling lagts till som prediktor. ME= modelling efficiency (modellens förklaringsgrad), MAE = mean absolute error (medelfel). Resultat som är bättre än samtliga ingående prediktioner är markerade med rött.*

Dataset	**ME (%)**	**MAE (kg / ha)**
1	**23**	25
2	71	16
3	< 0	38
4	< 0	47
5	< 0	29
6	< 0	41

Hur känsliga är modellerna för fel i indata?

Den modell som fungerat bäst för att prediktera Nopt är MARSplines med lerhalt, mullhalt, förväntad skörd och kväveskörd i nollrutor (dataset 2) som prediktorer. Modellen är dock beroende av att man har korrekta indata. I praktiken har man inte det. Skörd uppskattas av lantbrukarens och rådgivarens erfarenheter och kväveskörd i nollrutor kan uppskattas med genom mätningar med en optisk sensor (Yara N-sensor) i nollrutor (Wetterlind, 2010). Därför gjordes en känslighetsanalys för feluppskattning av skörd och kväveskörd i nollrutor. Marsplines-modellen tillämpades på korrekta indata samt på indata med olika grader av felskattningar (skörd ± 500 kg / ha, ± 1000 kg / ha och ± 3000 kg / ha och kväveskörd i nollrutor ± 10 kg / ha, ± 30 kg / ha och ± 50 kg / ha). Resultaten visas i figur 26. Figurerna är histogram för riktlinjernas eller de predikterade Nopt-värdenas avvikelse från den verklig Nopt bestämd i fältförsök. Ju toppigare och mer centrerad en kurva är, desto bättre. Man kan se att för vid måttliga felprognoser av skörd fungerar MARSplines-modellen bättre än dagens riktlinjer men för grova felprognoser fungerar modellen sämre än riktlinjerna. Känslighetsanalysen visar att det är viktigt med en bra skördeprognos och en bra uppskattning av markens kvävemineralisering för att man ska kunna kvävegödsla optimalt.

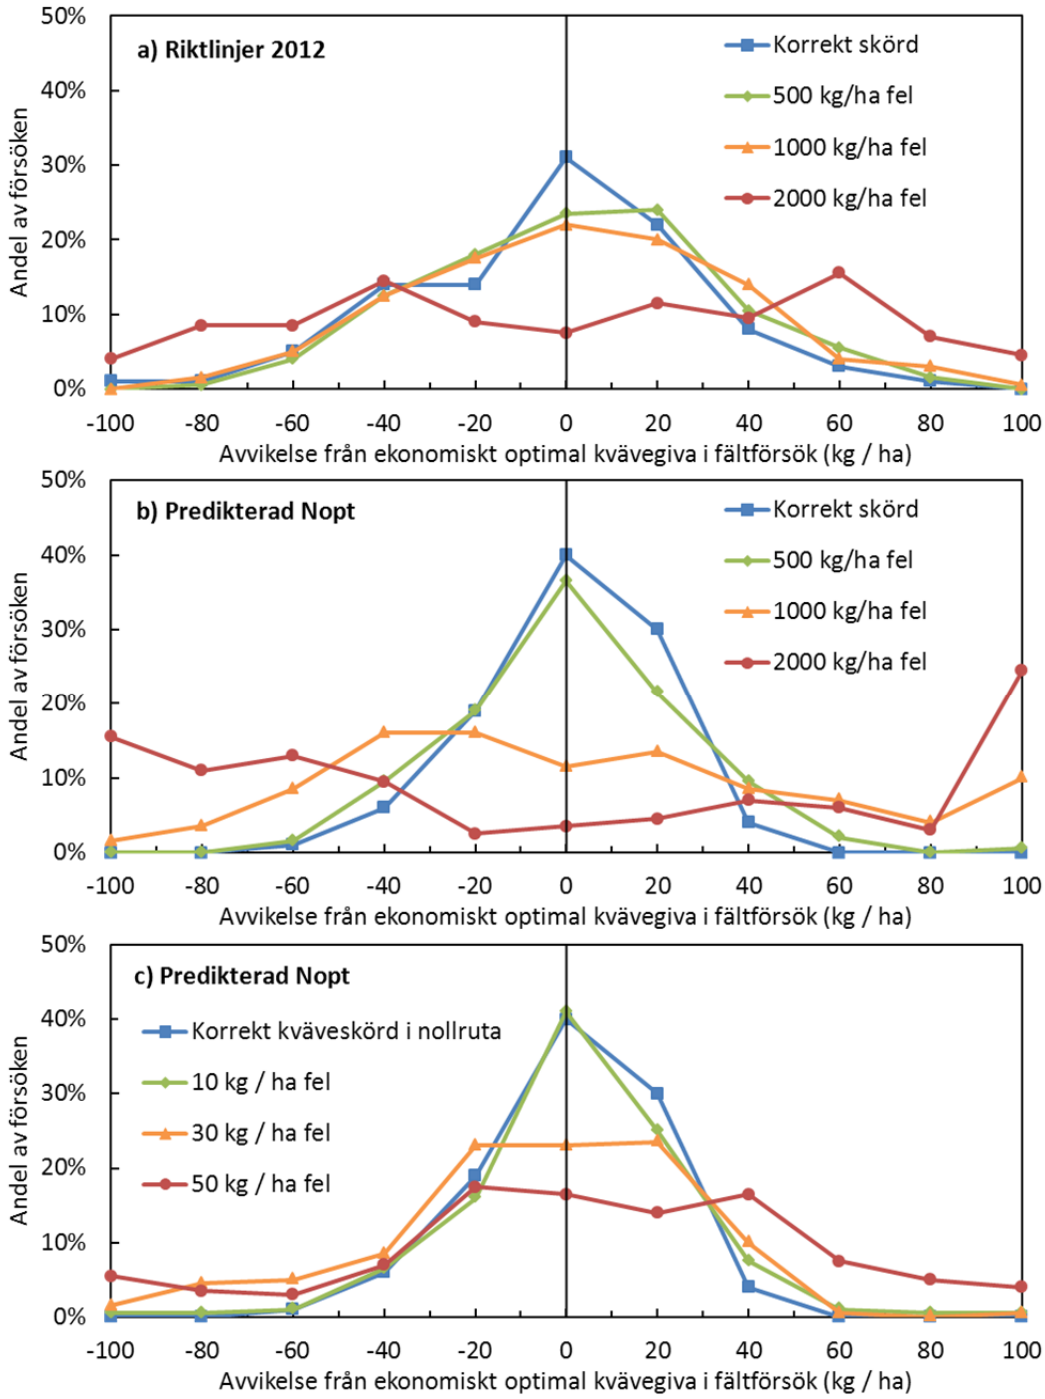

Figur 26. *Histogram för avvikelser från ekonomiskt optimal kvävegiva (Nopt) bestämd i fältförsök vid olika felprognoser för skörd och kväveskörd i nollrutor. a) Jordbruksverkets riktlinjer 2012, b-c) Nopt predikterad med MARSplines-modellen baserad på dataset 2. Punkterna vid ±100 kg avvikelse per hektar inkluderar även fel med en avvikelse > 100 kg / h. a Histogrammen är gjorda som linjediagram för att överskådligt kunna visa flera felskattingar i samma figur.*

Med hjälp av en Yara N-sensor kan kväveskörden i nollruta predikteras med ett medelfel på ungefär ± 10 kg / ha (Wetterlind, 2010). I figur 27 har två kurvor från figur 26 plockats ut för jämförelse. Båda histogrammen baseras på korrekt skörd. Det gröna histogrammet visar hur bra det kan bli om man uppskattar kväveskörd i nollruta med en N-sensor och det röda histogrammet visar Jordbruksverkets riktlinjer för 2012. De modellpredikterade värdena för Nopt har en större andel försök med små avvikelser från verklig Nopt än vad riktlinjerna för 2012 har men det kanske är ännu viktigare att notera de grova felskattningarna (> 60 kg N / ha fel) i princip har eliminerats genom att man använder en modell som tar hänsyn till markens kväveleverans. Användning av en N-sensor på en ogödslad yta av fältet tillsammans med en bra skördeprognos bör utgöra ett bra underlag för ekonomiskt och miljömässigt optimal gödsling.

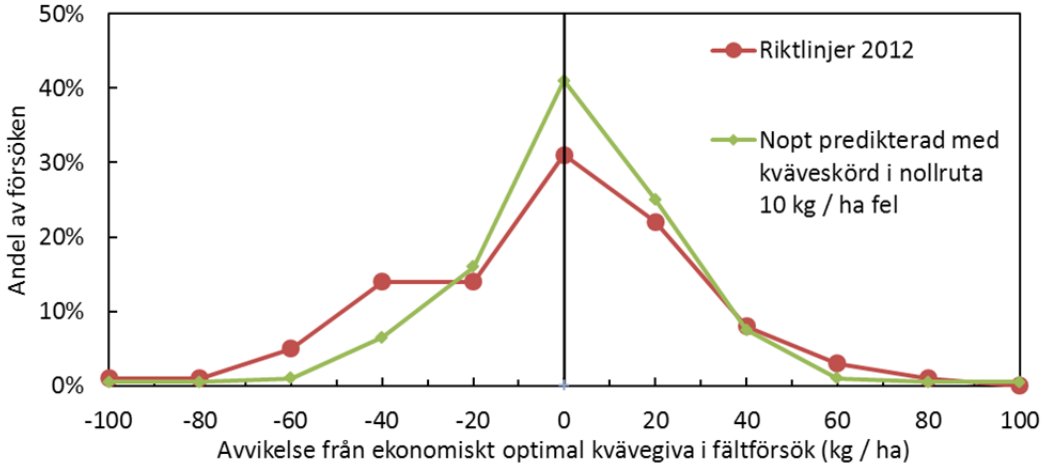

Figur 27. *Två utvalda histogram från figur 26 a (röd), 26 c (grön).*

I en MARSplines-modell kan antalet basfunktioner som baseras på en prediktor ge en fingervisning om hur viktig den prediktorn är. I figur 28 visas medelvärden för hur många basfunktioner som baseras på de fyra prediktorerna. Figuren indikerar att skörd och kväveskörd i nollrutor är viktigast. I samtliga tretton modeller ingår minst en basfunktion för lerhalt medan bara fyra av modellerna har med mullhalt som prediktor. Det testades hur bra MARSplines-modellen kunde prediktera Nopt om man saknar information om lerhalt och istället utgår från lerhalten alltid är medelhög (mellanlera). Resultaten visas i figur 29. Det blev inte mycket liten skillnad i histogrammen för avvikelserna från Nopt när man generellt använde mellanlera som indata istället för att använda korrekt klass för textur. Någon känslighetsanalys för mullhalt gjordes inte då den i de flesta fall inte kom med som prediktor.

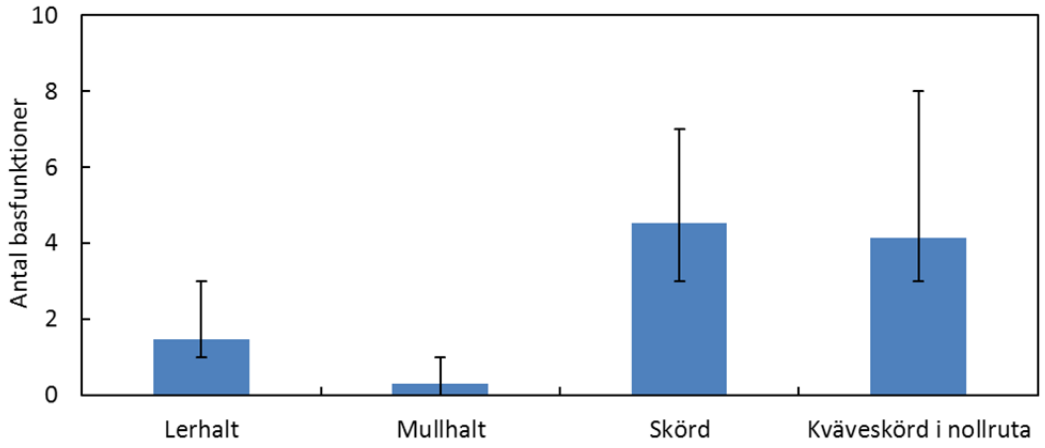

Figur 28. *Antal basfunktioner där prediktorerna lerhalt, mullhalt, skörd och kväveskörd i nollruta ingår. Staplarna visar medelvärden för de tretton modellerna och felstaplarna visar max och min.*

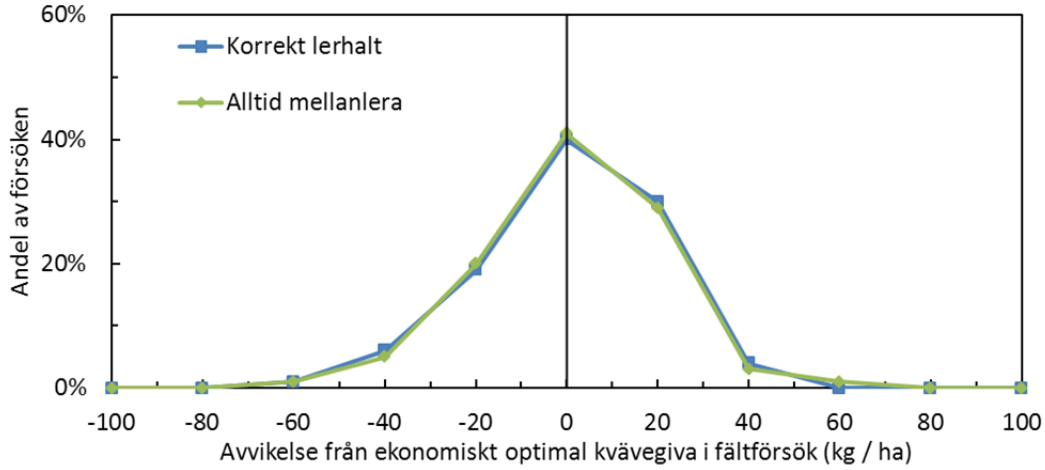

Figur 29. *Histogram för avvikelser mellan predikterad ekonomiskt optimal kvävegiva (MARSplines-modellen, dataset 2) och ekonomiskt optimal kvävegiva bestämd i fältförsök. Grönt histogram avser prediktioner där mellanlera angivits oavsett verklig klass och blått histogram avser prediktioner med korrekta indata. Punkterna vid ±100 kg avvikelse per hektar inkluderar även fel med en avvikelse > 100 kg / ha. Histogrammen är gjorda som linjediagram för att överskådligt kunna visa flera histogram i samma figur.*

Att prediktera skörden

Att utnyttja väderdata i multivariata prediktionsmodeller har hittills inte visat sig vara en framgångsrik väg att förbättra kvävegödslingsrekommendationerna. Eftersom den

optimala kvävegivan är starkt beroende av förväntad skörd, provades ändå om man kan utnyttja väderdata för att uppskatta den kommande skörden. Marsplines-modeller med fyra olika prediktorset testades: Temperatursumma (> 0ºC), PAR och nederbörd under 1) mars-maj, 2) mars-juni, 3) mars-juli och 4) mars-augusti. Dessutom ingick lerhalt och mullhalt som prediktorer. Resultaten av en årsvis korsvalidering visas i figur 30. Modellernas ME var mindre än noll i samtliga fall och man kan sluta sig till att detta inte heller var en framgångsrik väg att utnyttja väderdata. Att det inte fungerar att prediktera skörden med en multivariat statistisk metod, när man använder det aktuella årets indata, indikerar att det inte heller finns någon potential i att försöka prediktera skörd från lokalklimat (medelvädret för en längre tidsperiod).

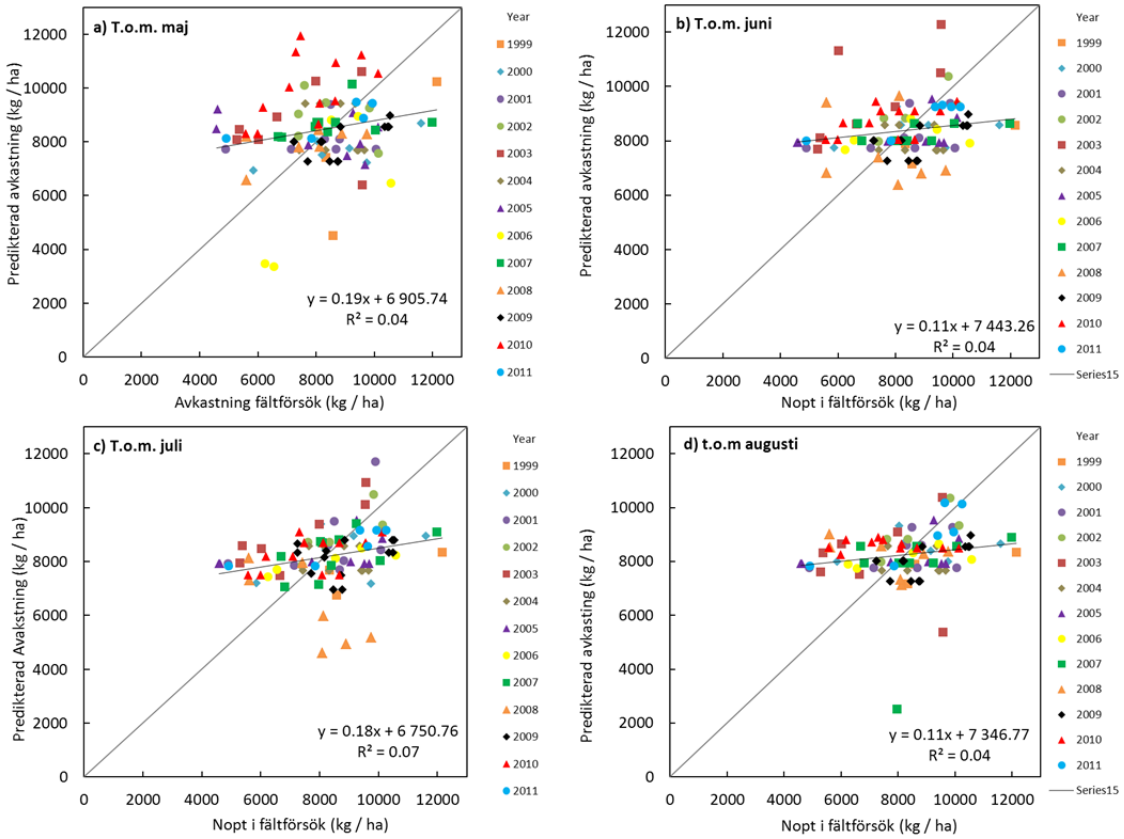

Figur 30. *Predikterad avkastning (MARSplines) baserat på lerhalt mullhalt samt kumulerade väderdata från mars- a) maj, b) juni, c) juli och d) augusti.*

Att prediktera Nopt med mekanistiska grödmodeller

Problemet med att använda väderdata i empiriska statistiska modeller ligger troligen i svårigheten att sammanfatta en hel säsongs väder i ett fåtal relevanta variabler. Här kan mekanistiska grödmodeller vara ett bättre alternativ. De bygger upp skörden dag för dag med grödspecifika program för hur kol och kväve assimileras (tas upp) och allokeras

(fördelas) inom växten under olika omgivningsförutsättningar (läs mer i Hay & Porter, 2006). Det finns olika modeller som kräver olika indata men viss information om marken samt dygnsvis nederbörd, temperatur och instrålning är vanliga krav. Man kan antingen tänka sig att använda modellen för att direkt prediktera Nopt (genom simuleringar vid flera kvävenivåer) men man kan också tänka sig att använda den för att sammanfatta väderdata i ett värde för skördepotential som sedan används i en empirisk modell.

Kan kväveeffektiviteten och det ekonomiska resultatet förbättras?

De hypoteser som skulle testas i projektet var:

1. Med ett platsspecifikt beslutsstöd blir riktgivan mer rätt för varje gård.
2. Kväveeffektiviteten kan förbättras med platsspecifika riktgivor för kväve.
3. Det ekonomiska resultatet kan förbättras med platsspecifika riktgivor för kväve.

För att beräkna kväveeffektiviteten och den ekonomiska vinsten om man skulle gödsla efter en predikterad Nopt använde vi oss av produktionsfunktioner för kväve och för skörd (figur 31).

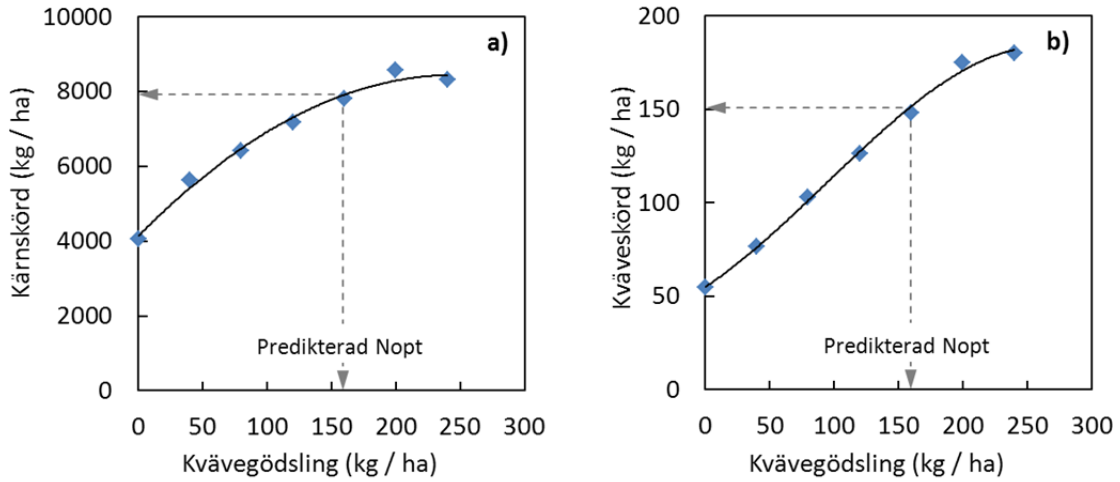

Figur 31. *Produktionsfunktioner för a) kärnskörd och b) kväveskörd för ett av de ingående försöken (Adb: 03K082). Pilarna visar predikterad ekonomiskt optimal kvävegiva (Nopt) enligt MARSplines-modellen baserad på dataset 2 samt kärnskörd eller kväveskörd vid denna kvävegiva. Verklig Nopt var i detta försök 176 kg / ha.*

Kväveeffektiviteten vid gödsling enligt en predikterad Nopt beräknades från produktionsfunktionen för kväve som:

$$Kväveeffektivitet = \frac{Kväveskörd}{Predikterat\ Nopt}$$

Den ekonomiska vinsten vid gödsling enligt en predikterad Nopt beräknades från produktionsfunktionen för kärna samt ett spannmålspris på 2 kr / kg och ett kvävepris på 20 kr / kg. För övriga kostnader (utsäde, övrig växtnäring, drivmedel, växtskydd, transport, torkning och analys) sattes ett fast pris (4000 kr) per hektar:

$$Vinst = 2\ {}^{kr}/_{kg} \times Kärnskörd\ - 20\,{}^{kr}/_{kg} \times predikterad\ Nopt - 4000\ {}^{kr}/_{ha}$$

Dessa enkla uppskattningar av träffsäkerheten i Nopt, kväveeffektivitet och ekonomisk vinst gjordes för den bästa modellen (MARSplines, dataset 2) och för Jordbruksverkets riktlinjer 2012. Skillnader i kväveeffektivitet och vinst utvärderades med parvis t-test mellan Prediktioner gjorda med MARSplines modellen (dataset 2) och Jordbruksverkets riktlinjer för 2012. Resultaten redovisas i tabell 8.

Tabell 8. *Medelvärden och standardavvikelser för de 100 utvalda försöken samt resultaten av parvis t-test mellan värden för om man gödslat enligt riktlinjerna för 2012 och om man gödslat enligt MARSplines-modellen (dataset 2). ***, p < 0,001; *, P < 0,001.*

Variabel	Fältförsök	Riktlinjer	MARSplines	t-test
Avvikelse från försök (kg / ha)	-	24±21	15±12	***
Kväveeffektivitet (%)	91±24	87±10	91±29	p = 0,1
Vinst (kr / ha)	9369±2856	9201±2811	9300±2841	***

Fortsatt arbete

I det kommande arbetet ska vårkorn undersökas. De empiriska modeller för skörd och ekonomiskt optimal kvävegiva som baserades på väderdata fungerade dåligt i höstvete. Det ska inte tolkas som att det lokala vädret saknar betydelse. Orsaken är snarare att det är problematiskt att sammanfatta en hel säsongs väder i ett fåtal relevanta variabler. Korn är en vårgröda, vilket ger andra förutsättningar än för höstvete, eftersom grödan inte påverkas direkt av vädret under höst och vintersäsongen med utvintring *et. c.* men vi bedömer ändå inte chansen att hitta väl fungerande empiriska modeller av den typ vi hittills använt för ekonomiskt optimal kvävegiva baserat på väderdata som avsevärt mycket större. Vi vill däremot istället testa att använda mekanistiska grödmodeller som utnyttjar lokala väderdata på ett annat sätt: skörden byggs upp dag för dag enligt ett program som anpassas till lokala markförhållanden och grödans egenskaper. På så sätt tar man även hänsyn till när i grödans utveckling olika faktorer är begränsande. På detta sätt

kan tillgängliga väderdata utnyttjas bättre. Vi avser att använda modellen Sirius (http://www.rothamsted.ac.uk/mas-models/sirius.php), som har relativt små krav på ytterliga indata utöver vädret. Modellen har utvecklats i Storbritannien och används för att göra dagliga prognoser för slutlig skörd. Vi bedömer att det dataset som tagits fram i projektet utgör en bra grund för att utvärdera den här typen av modeller som verktyg för att optimera kvävegödslingen lokalt genom platsanpassade skördeprognoser.

Sammanfattande slutsatser

- Förutsatt att man har korrekta indata (lerhalt, mullhalt, skörd, och markens kväveleverans) kan man ta fram platsspecifika riktgivor som är bättre än dagens riktlinjer för kvävegödsling. De platsspecifika riktlinjerna gav ett statistiskt signifikant bättre ekonomiskt utbyte och förbättrade kväveeffektiviteten. Förbättringen av kväveeffektiviteten var dock inte statistiskt signifikant.
- För att få mer träffsäkra kvävegivor är det framför allt två saker som är viktiga: att man kan uppskatta platsens kvävemineralisering och att man har en bra skördeprognos. Vill man förbättra dagens riktgivor ska man satsa på att hitta bra verktyg för att uppskatta dessa lokalt.
- Man kan använda en optisk sensor (Yara N-sensor) i nollrutor för att uppskatta markens kväveleverans med rimliga felmarginaler.
- Att använda väderdata i empiriska modeller för att göra skördeprognoser var inte framgångsrikt. Här krävs mer utvecklingsarbete. Mekanistiska tillväxtmodeller skulle kunna vara ett bra verktyg, eventuellt i kombination med N-sensormätningar.
- Det fanns tendenser till skillnader i produktionsfunktionens parametrar mellan de stora jordbruksområdena. Det fanns också trender i hur produktionsfunktionernas parametrar varierade med ler- och mullhalt. Det fungerade relativt bra att prediktera parametrarna baserat på flera av de olika uppsättningarna av indata. Dock var inte de ekonomiskt optimala kvävegivor som beräknats från dessa predikterade parametervärden bättre än dagens riktlinjer.
- Någon storskalig variation kunde inte skönjas när ekonomiskt optimala kvävegivan och kväveskörden i nollrutor ritades ut på en karta. Den geografiska variationen verkar domineras av mer småskalig variation i mineraliserings- och skördepotential, både mellan platser och mellan år.
- Några lärdomar från den empiriska modelleringen: det var viktigare vilka indata man baserade modellerna på än vilken typ av modell man använde. Att kombinera flera modeller förbättrade inte resultaten men att lägga på begränsningar på modellberäkningarna var ett användbart sätt att komma tillrätta med extrema värden.

Referenser

Albertsson, B., 2012. Riktlinjer för gödsling och kalkning 2012. Jordbruksverket. Rapport JO11:21.

Börjesson, T., Stenberg, B., Lindén, B., Jonsson, A., 1999. NIR spectroscopy, mineral nitrogen analysis and soil incubations for the prediction of crop uptake of nitrogen during the growing season. Plant and Soil 214, 8.

Delin, S., Lindén, B., 2002. Relations between net nitrogen mineralization and soil characteristics within an arable field. Acta Agriculturae Scandinavica Section B-Soil and Plant Science 52, 8.

Delin, S., Stenberg, M., 2010. Effect of nitrogen fertilization on nitrate leaching in relation to grain yield response in Sweden. In: M.S. Sachdev (Ed.), 5th International Nitrogen Conference 2010, New Delhi, India, pp. 235.

Eriksson, J., Nilsson, I., Simonsson, M., 2005. Wiklanders marklära. Studentlitteratur. ISBN: 978-91-44-02482-0

Frostgård, G., Andersson, A., Olsson, C.M., Gruvaeus, I., 2008. Yaras handsensor - aktuell teknik för att finna miljömässigt och ekonomiskt optimal kvävegiva.

Gruvaeus, I., 2007. Kvävestrategi i höstvete.

Hay R., Porter J. 2006. The physiology of crop yield. Blackwell publishing, Oxford, UK: ISBN 978-14051-0859-1.

Jordbruksverket, 2008. Minska Jordbrukets klimatpåverkan. Del 1 Introduktion och några åtgärder/styrmedel.

Krijger, A-K. 2013 Kvävebehov till höstvete under olika förutsättningar. Försöksrapport 2013. Mellansvenska försökssamarbetet och Svensk Raps. Under tryckning.

Lord, E.I., Mitchell, R.D.J., 1998. Effect of nitrogen inputs to cereals on nitrate leaching from sandy soils. Soil Use and Management 14(2), 78-83.

Mattsson, L., 2004. Kväveintensitet i höstvete vid olika förutsättningar. Institutionen för markvetenskap. Avd. för växtnäringslära.Rapport 209.

Raun, W.R., Solie, J.B., Stone, M.L., 2010. Independence of yield potential and crop nitrogen response. Precision Agriculture in press.

Scharf, P.C., Kitchen, N.R., Sudduth, K.A., Davis, J.G., 2006. Spatially variable corn yield is a weak predictor of optimal nitrogen rate. Soil Science Society of America Journal 70(6), 2154-2160.

Schmidt, J.P., Sripada, R.P., Beegle, D.B., Rotz, C.A., Hong, N., 2011. Within-Field Variability in Optimum Nitrogen Rate for Corn Linked to Soil Moisture Availability. Soil Science Society of America Journal 75(1), 306-316.

StatSoft, Inc. (2013). Electronic Statistics Textbook. Tulsa, OK: StatSoft. http://www.statsoft.com/textbook/.

Valkama, E., Salo, T., Esala, M., Turtola, E. Nitrogen balances and yields of spring cereals as affected by nitrogen fertilization in northern conditions: A meta-analysis.

Wetterlind, J., 2010. Mätningar med Yara N-senor för att skatta markens kvävelevererande förmåga/Using Yara N-sensor to estimate soil nitrogen mineralisation. SLU, Sveriges lantbruskuniversitet, Institutionen för mark och miljö, Precisionsodling och pedometri.

Wetterlind, J., Jonsson, A., Stenberg, B., 2007. Indelning av fält in mineraliseringszoner för varierad kvävegödsling. Division of precision agriculture, Swedish University of Agricultural Sciences, pp. 24.

Wetterlind, J., Stenberg, B., Jonsson, A., 2008. Near infrared reflectance spectroscopy compared with soil clay and organic matter content for estimating within-field variation in N uptake in cereals. Plant and Soil 302(1-2), 317-327.

Appendix 1 .

***Tabell 1**. Försök som ingår i analyserna. Mer information om försöken (försöksplaner et.c.) kan sökas ut på SLU fältforsks hemsida (http://www.slu.se/sv/fakulteter/nl-fakulteten/om-fakulteten/ovriga-enheter/faltforsk/resultat/enskilda/frisok/).*

Adb-nummer	År	Adb-nummer	År	Adb-nummer	År
39884	1999	03E106	2004	03L113	2009
39887	1999	03F007	2005	03L114	2009
39888	1999	03F009	2005	03L116	2009
03A022	2000	03F010	2005	03L118	2009
03A023	2000	03F011	2005	03L119	2009
03A024	2000	03F012	2005	03L120	2009
03A025	2000	03F092	2005	03M081	2010
03A026	2000	03F094	2005	03M083	2010
03A027	2000	03F095	2005	03M084	2010
03B100	2001	03G010	2006	03M088	2010
03B104	2001	03G014	2006	03M091	2010
03B105	2001	03G023	2006	03M092	2010
03B110	2001	03G024	2006	03M093	2010
03B111	2001	03G027	2006	03M094	2010
03B112	2001	03H015	2007	03M095	2010
03B113	2001	03H017	2007	03M097	2010
03B115	2001	03H018	2007	03M098	2010
03C035	2002	03H019	2007	03M099	2010
03C046	2002	03H091	2007	03N089	2011
03C047	2002	03H092	2007	03N091	2011
03C048	2002	03H094	2007	03N092	2011
03C049	2002	03H096	2007	03N098	2011
03C050	2002	03H097	2007	03N099	2011
03D105	2003	03H102	2007	03N101	2011
03D107	2003	03K016	2008		
03D126	2003	03K020	2008		
03D127	2003	03K082	2008		
03D128	2003	03K088	2008		
03D130	2003	03K089	2008		
03D163	2003	03K091	2008		
03E075	2004	03K092	2008		
03E078	2004	03L020	2009		
03E079	2004	03L022	2009		
03E080	2004	03L024	2009		
03E103	2004	03L109	2009		
03E104	2004	03L110	2009		
03E105	2004	03L111	2009		
03E106	2004	03L112	2009		

Appendix 1