

**CHAID LĒMUMU KOKU UN NEIRONU TĪKLU METOŽU
PIELIETOJUMS GRAUDKOPIBAS NOZARES UZŅĒMUMU RAŽAS
PROGNOZĒŠANĀ**
*APPLICATION OF CHAID DECISION TREES AND NEURAL NETWORKS
METHODS IN FORECASTING THE YIELD OF CEREAL INDUSTRY
COMPANIES*

Autore: **Lāsma Priževoite**, Rēzeknes Tehnoloģiju akadēmija, e-pasts:
lasma.prizevoite@gmail.com

Zinātniskā darba vadītājs: **Pēteris Grabusts, Dr.sc.ing., prof.**, e-pasts: peteris.grabusts@rta.lv

Zinātniskā darba vadītāja: **Inta Kotāne, Ph.D., docente**, e-pasts: inta.kotane@rta.lv

Rēzeknes Tehnoloģiju akadēmija
Atbrīvošanas aleja 115, Rēzekne, Latvija

Abstract. *Within the research the most important factors affecting the grain yield and their impact indicators were considered. The application of CHAID decision trees and neural networks in forecasting aspects of the grain-growing industry was investigated. In the study, the organic agricultural companies of the Latgale region, which are engaged in grain cultivation, were selected and the harvest volumes of the companies and their influencing factors were collected. Based on the collected data, grain yield forecasting was performed using CHAID decision tree and neural network methods.*

Keywords: *CHAID decision tree, neural networks, grain-growing industry, yield, forecasting.*

Ievads

Pētījuma aktualitāte saistāma ar to, ka graudkopības nozares nepārtrauktās izmaiņas un izaicinājumi, kas ietver dažādu faktoru ietekmi uz graudaugu ražas apjomiem, prasa graudkopības uzņēmumiem pielāgoties jaunām tehnoloģijām, tostarp mākslīgā intelekta metožu pielietošanu ražas prognozēšanai, lai saglabātu konkurētspēju un sekmētu ilgtspējīgu attīstību.

Pētījuma problēma ir, ka tradicionālās ražas prognozēšanas metodes, kas atkarīgas no cilvēka sprieduma, bieži ir nepietiekamas un neobjektīvas, tāpēc, lai nodrošinātu precīzas un uzticamas prognozes graudkopības uzņēmumam, ir būtiski izmantot mākslīgā intelekta metodes ražas prognozēšanā.

Pētījuma mērķis: izpētīt CHAID lēmumu koku un neironu tīklu metožu pielietojumu graudkopības nozares uzņēmumu ražas prognozēšanā.

Pētījuma uzdevumi:

1. Izpētīt graudkopības nozares teorētiskos aspektus.
2. Analizēt graudaugu ražu ietekmējošos faktoros.
3. Veikt CHAID lēmumu koku un neironu tīklu metožu pielietojumu graudaugu ražas prognozēšanai.
4. Izteikt secinājumus un izvirzīt priekšlikumus.

Pētījuma objekts: graudkopības nozare, prognozēšana.

Pētījuma priekšmets: ražas prognozēšanas iespējas graudkopības nozares uzņēmumā.

Hipotēze: mākslīgā intelekta metožu pielietojums uzlabo graudkopības nozares uzņēmumu ražas prognozēšanas precizitāti.

Pētījuma periods: no 2008.gada līdz 2023.gadam.

Pielietotās pētīšanas metodes: dokumentu analīze, analīzes metode, monogrāfiskā jeb aprakstošā metode, grafiskā metode.

Materiāli un metodes


Graudkopība ir viena no vadošajām lauksaimniecības nozarēm, kur ik sezonu lauksaimniekiem nākas saskarties ar izaicinājumu – efektīvi plānot un īstenot darbības, lai paaugstinātu ražu un tās kvalitāti [1]. Tomēr graudaugu ražas apjomi var būt atkarīgi no dažādiem to ietekmējošiem faktoriem, līdz ar to, ir nozīmīgi izpētīt to parametrus un ietekmes rādītājus. Ņemot vērā to, ka ziemāju, tas ir, graudaugu kuri tiek sēti rudenī un vasarāju, kā arī pārējo graudaugu ražu ietekmējošie faktori var būtiski atšķirties, pētījuma ietvaros netiks ņemti vērā ziemāju graudaugu sējumu ražu ietekmējošie faktori. Nozīmīgākie graudaugu ražu ietekmējošie faktori un to rādītāji apkopoti 1. tabulā [2] [3] [4] [5] [6] [7] [8] [9] [10] [11].

1.tabula

Graudaugu ražu ietekmējošo faktoru apkopojums (autores veidota)

Nr. p.k.	Faktors	Ietekme	Ietekmes rādītājs
1	2	3	4
1	Dīgtspēja (grauda svars ņemot tūkstoš graudus)	Labvēlīga	51 g un vairāk
		Vidēja	26 – 50 g
		Nelabvēlīga	1 – 25 g
2	Dīgtspēja (grauda sēšanas dziļums)	Labvēlīga	60 – 69 mm
		Vidēja	70 – 83 mm; 23 – 59 mm
		Nelabvēlīga	84 mm un vairāk; 22 mm un mazāk
3	Graudaugu sēklas kvalitāte (proteīna saturs)	Labvēlīga	14,5 % un vairāk
		Vidēja	13,1 – 14,4 %
		Nelabvēlīga	13 % un mazāk
4	Augsnes kvalitāte (pHKCl līmenis)	Labvēlīga	6 – 6,5
		Nelabvēlīga	5,9 un mazāk 6,6 un vairāk
5	Izsējas norma (dīgtspējīgu sēklu daudzums uz vienu m ²)	Labvēlīga	400 – 500 un vairāk
		Vidēja	300 – 399
		Nelabvēlīga	299 un mazāk
6	Temperatūra	Labvēlīga	20 – 25 °C
		Vidēja	26 – 31 °C; 7 – 25 °C
		Nelabvēlīga	32 °C un vairāk; 6 °C un mazāk
7	Nokrišņu daudzums gadā	Labvēlīga	50 – 100 cm
		Nelabvēlīga	49 cm un mazāk 101 cm un vairāk
8	Augsnes apstrādes veids	Tradicionālā augsnes apstrāde	-
		Minimālā augsnes apstrāde	-
		Tiešā sēja	-

Kā redzams 1. tabulā, nozīmīgs faktors, kas ietekmē graudaugu ražas apjomus ir izmantotās graudu šķirnes sēklas dīgtspēja. Ir noteikts, kā tiek ietekmēta daudzu graudaugu šķirņu agrīna augšana pēc sēklu izmēra un svara, kā attēlots 1.attēlā.



1.attēls. **Graudu svara ietekme uz dīgspēju procentos [2]**

Balstoties uz J. J. Blake, J. H. Spinka un C. Dyera pētījumu, tiek noteikts, optimālais sēšanas dziļums ir 6 cm, kas nodrošina stādu izturību un labus ražas dīgspējas rezultātus [2].

Ražas apjomus ietekmē izvēlēta graudaugu sēklas kvalitāte. Sēklas kvalitātes galvenais rādītājs ir proteīna saturs graudos, kur E kvalitātes klase tiek apzīmēta kā augsta, ar proteīna saturs graudos >14.5 %, A kvalitātes klase vidēja, ar proteīna saturu graudos 14 %, kā arī B kvalitātes klase zema, ar proteīna saturu graudos 12- 13 % [12].

Nozīmīgs faktors ir augsnes kvalitāte, būtisks rādītājs kas raksturo augsnes kvalitāti ir pH līmenis, kas lauksaimniekam ir samērā viegli nosakāms veicot augsnes analīzes, kas graudaugiem kopumā, ir vidēji 6,0 līdz 6,5 pHKCl.

Izsējas norma var ietekmēt ražas lielumu, līdz ar to, tās kvalitāti un ražas apjomus. Balstoties uz 1.tabulā apkopotajiem datiem var secināt, ka augstākos ražas apjomus var sasniegt, ja izsēja ir vidēji 400 – 500 dīgspējīgu sēklu uz m².

Graudaugu augšanas procesu būtiski ietekmē temperatūras diapazons. Optimālā temperatūra tiek uzskatīta par 20-25°C, kas nozīmē, ka dīgšana ir efektīvāka šajā temperatūras diapazonā. Katrs 1°C temperatūras paaugstinājums virs 23°C vidējās temperatūras samazina graudaugu ražu par aptuveni 10% [13], savukārt temperatūra virs 32 °C negatīvi ietekmē graudauga augšanu, kā arī ir kritiska temperatūra, kas ilgstoši zemāka par 6 °C [14].

Nokrišņu daudzums ir nozīmīgs faktors graudkopības nozarē. Ja nav pietiekami daudz nokrišņu, graudaugi nevar augt, un raža var tikt ierobežota. Lielākajai daļai graudaugu nepieciešams no 50 līdz 100 cm lietus nokrišņu gadā [4]. Mitruma vai sausuma stress rada apmēram 30–70 % graudaugu produktivitātes zudumu kultūraugu augšanas periodā [5].

Kā redzams 1. tabulā, tiek izšķirti trīs augsnes apstrādes veidi ar atšķirīgiem raksturojošiem rādītājiem. Tradicionālā augsnes apstrāde attiecas uz aršanu, kas ietver augsnes apvēršanu [7], kas nodrošina barības elementu pieejamību visā aramkārtas slānī, ierobežo nezāles, veicina pārējo tehnoloģisko operāciju vieglāku izpildi [6]. Minimālās augsnes apstrāde ir metode, kur neveic augsnes apvēršanu. Maksimālais kultivēšanas dziļums ir ne dziļāks par 10 cm un / vai noteikts augsnes virsmā atstātajām augu atliekām procentuālais segums procentos, parasti 30%, kā arī pielietojot minēto metodi samazinās erozijas un garozas veidošanās risks, jo uz augsnes virsmas paliek salmu atliekas [9]. Savukārt tiešā sēja ir metode, kur sēkla tiek ievietota augsnē, neveicot iepriekšējās kultūras kultivēšanu, galvenokārt tiek izmantota sausos reģionos. Samazinās sadīgušo sēklu un nezāļu mehāniska apkarošana, taču nav iespējams izlīdzināt nevienmērīgi izkliedētas augu atliekas. Pielietojot būtiski ietaupās laiks un nauda, taču vienlaikus ir palielināts augu slimību izplatības risks [11].

Var secināt, ka graudaugu ražu var ietekmēt tādi faktori kā grauda svars, grauda sēšanas dziļums, sēklas kvalitāte, augsnes kvalitāte, izsējas norma, gaisa temperatūra, nokrišņu daudzums un augsnes apstrādes veids, turklāt katram no faktoriem tiek definēts ietekmes rādītājs uz graudaugu ražu.

Graudaugu ražas prognozēšana ir svarīgs lauksaimniecības aspekts, kas palīdz lauksaimniekiem pieņemt apzinātus lēmumus par audzētajām kultūrām [16], kas ir būtiski resursu optimizācijai un ieguldījumu plānošanai ilgspējīgas ražošanas nodrošināšanai [17].

Graudaugu ražas prognozēšanai var izmantot lēmumu koku metodi, kas ietver mašīnmācīšanās algoritmu izvēli un parametru noteikšanu, balstoties uz apmācības paraugiem. Lēmumu koku metode tiek sekmīgi pielietota graudkopības nozarē, tajā skaitā ražas prognozēšanā, izmantojot apmācības datus un izveidojot lēmumu koku, kurā tiek parādīta katra funkcija ar mezglu, metode prognozē mērķa mainīgo un nodrošina vienkāršu interpretācijas iespēju [18]. CHAID viens no izplatītākajiem lēmumu koku veidiem, kas tiek izmantots [19], CHAID algoritms sadala mezglus, lai iegūtu hī-kvadrāta (chi-square) vērtības. Hī-kvadrāta vērtība ir atšķirība starp standarta, paredzamo scenāriju un faktiskajiem rezultātiem, kas novēroti datos. Maksimālā hī-kvadrāta vērtība ir statistiski nozīmīgākais rezultāts CHAID lēmumu kokā jeb spēcīgākā saikne starp diviem mainīgajiem no atrastajām hī-kvadrāta vērtībām [20].

Efektīvs instruments ražas prognozēšanā ir neironu tīkli, kas var atrast pamatā esošo datu attēlojumu bez manuālas funkciju ievades, kur ir vairāki nelineāri slāņi, kas pārveido neapstrādātos ievades datus augstākā un abstraktākā attēlojumā katrā slānī. Neironu tīkla dziļumam ir būtiska ietekme uz tā veikspēju [21]. Neironu tīkla izmantošanai ražas prognozēšanai ir priekšrocības salīdzinājumā ar citām matemātiskās modelēšanas metodēm. Neironu tīkla tehnoloģiju izmantošana ļauj prognozēt ražas apjomus, pamatojoties uz tam dotajiem attiecīgiem datiem [22].

Var secināt, ka graudaugu ražas prognozēšana ir būtisks lauksaimniecības aspekts, kas palīdz optimizēt resursus. CHAID lēmumu koki, un neironu tīkli ir efektīvi rīki šajā jomā, nodrošinot precīzas prognozes un atvieglojot lēmumu pieņemšanu lauksaimniecības procesos.

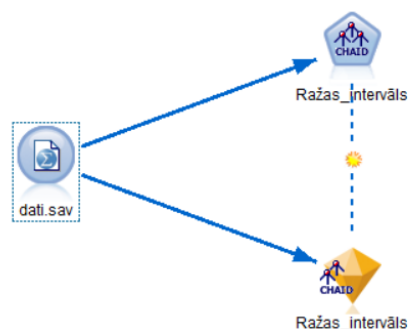
Rezultāti un izvērtējums

Lai raksturotu graudkopības nozares uzņēmumus un to darbības rādītājus, tika izraudzīti četri Latgales reģiona bioloģiskās lauksaimniecības uzņēmumi, SIA "A", SIA "B", SIA "C" un SIA "D", kuru pamatdarbības veids ir graudaugu audzēšana. Tika apkopoti ražu ietekmējošo faktoru rādītāji un ražas apjomi SIA "A" no 2011. līdz 2023. gadam, SIA "B" no 2008. līdz 2023. gadam, SIA "C" no 2013. līdz 2023. gadam un SIA "D" no 2013. līdz 2023. gadam. Apkopotie dati tika apstrādāti prognozējošās analītikas un statistiskās analīzes programmatūras pakotnē IBM SPSS Statistics, kur katrai no vērtībām tiek piešķirts identifikators jeb kods.

Pētījuma metodoloģija balstās uz šādām darbībām:


1. Uz sākotnējo datu pamata tiek veidots lēmumu koks.
2. Uz to pašu datu pamata tiek konstruēts neironu tīkls, kas tiek apmācīts.
3. Tiek veikta neironu tīkla testēšana, lai varētu pie noteiktiem faktoru rādītājiem veikt ražas prognozēšanu.

Strukturētu datu tālākai analīzei autore izmantoja IBM SPSS Modeler, Strukturētos datus, kas tika apkopoti IBM SPSS Statistics un definēti ar faila nosaukumu "dati", autore importēja un apstrādāja IBM SPSS Modeler, kā parādīts 2. attēlā.



2.attēls. CHAID lēmumu koka modelis (autore veidots)


CHAID lēmumu koka analīzes rezultātā tiek definēta prognozēšanas faktoru nozīmība, kā parādīts 3. attēlā.



3.attēls. CHAID lēmumu koka modeli definētā prognozēšanas faktoru nozīmība (autores veidots)


Kā redzams 3.3.attēlā, balstoties uz CHAID lēmumu koku analīzes rezultātiem, kā nozīmīgāko graudaugu ražu ietekmējošo faktoru var definēt “temperatūra”, taču vismazāk nozīmīgu “izsējas norma”.

CHAID lēmumu koka modelis apkopo faktoru ietekmi un nozīmību, taču, lai varētu veikt graudaugu ražas prognozēšanu, modelim nepieciešams pievienot neironu tīkla analīzi, kā parādīts 4. attēlā.



4.attēls. CHAID un neironu tīkla modelis (autores veidots)

Kā redzams 4. attēlā, arī neironu tīklā ražas intervāls tiek definēts kā mērķis, kas atkarīgs no pārējiem ražu ietekmējošiem faktoriem, savukārt neironu tīkla definētā faktoru nozīmība apkopota 5.attēlā.



5.attēls. Neironu tīkla modeli definētā apmācības faktoru nozīmība (autores veidots)

Lēmumu koku un neironu tīklu apmācības rezultātā iegūtie nozīmības faktori atšķiras tāpēc, ka abos gadījumos tiek izmantoti dažādi apmācības algoritmi, kā rezultātā faktoru ietekme var būt dažāda. Katrs algoritms uzsvēr dažādas datiem raksturīgās attiecības, līdz ar to, ir iespējams izprast kādi faktori katrā no metodēm ietekmē modeli un prognozes.

Var secināt, ka balstoties uz CHAID lēmumu koku un neironu tīklu modeli faktors “temperatūra” ir nozīmīgākais graudaugu ražas prognozēšanā, savukārt vismazāk nozīmīgs faktors CHAID lēmumu koku modelī ir “izsējas norma”, bet lēmumu koka modelī “augšnes kvalitāte”, kas pamatojams ar to, ka tie izmanto dažādus apmācības algoritmus un uzsvēr dažādas datiem raksturīgās īpašības.

Lai pārbaudītu izveidotā prognozēšanas modeļa ticamību, tiek veikta datu testēšana, tas ir, no kopējā datu kopuma tiek atlasīta pēdējā datu rindiņa (SIA “D” dati par 2023. gadu) un nodzēsta ražas intervāla vērtība, kas bija definēta ar “3” jeb “Vidēja”, robežās 3,0 – 4,0 t/ha (fails “dati-test”), ar mērķi, pārbaudīt vai apmācītais modelis atpazīs zināmo vērtību, kura tika nodzēsta. Testēšanas datu kopa ir savienota ar izveidoto CHAID lēmumu koku un neironu tīkla modeli, un testēšanas rezultāts attēlots datu kopā “Table” (6. attēls).

Ražas_intervāls	Uzņēmuma_nosaukums	Gads	Grauda_svars	Sēšanas_dziļums	Sēklas_kvalitāte	Augsnes_kvalitāte
\$null\$	SIA D	2023....	Vidēja	Labvēlīga	Vidēja	Labvēlīga

Izsējas_norma	Temperatūra	Nokrišņi	Augsnes_apstrāde	\$N-Ražas_intervāls	\$NC-Ražas_intervāls
Labvēlīga	Nelabvēlīga	Labvēlīga	Tradicionālā	Vidēja (3,0-4,0)	0.692

6.attēls. Prognozēšanas modeļa testēšanas rezultāti (autores veidots)

Testēšanas rezultāts liecina, ka ražu ietekmējošo faktoru vērtības ar 69 % ticamības rādītāju atbilst ražas intervālam “vidēja”, kas atbilst sākotnējai datu vērtībai, līdz ar to, var uzskatīt, ka izveidotais prognozēšanas modelis ir samērā precīzs.

Balstoties uz apmācītajiem datiem, graudkopības nozares uzņēmumi var veikt nākamā gada ražas prognozes, ņemot vērā iegūto ticamības rādītāju, kas sniegtu iespēju identificēt un novērst iespējamās ražas samazināšanās vai citus nelabvēlīgus ražu ietekmējošos faktorus, kas kopumā ietekmē uzņēmuma darbību.

SIA “A” tika lūgts sniegt informāciju par zināmajiem 2024. gada ražu ietekmējošo faktoru rādītājiem, kas apkopoti 2. tabulā.

SIA "A" ražu ietekmējošo faktoru rādītāji 2024. gadā (autores veidota)

Nr.p.k.	Faktors	Rādītājs 2024. gadā	Ietekmes rādītājs
1	Vidējais tūkstoš graudu svars (g)	50-55	Labvēlīga (1)
2	Vidējais grauda sēšanas dziļums (mm)	30-40	Vidēja (2)
3	Vidējais proteīna saturs graudā (%)	62	Labvēlīga (1)
4	Augsnes pHKCl	6,4	Labvēlīga (1)
5	Izsējas norma (sēklas uz vienu m ²)	450 - 500	Labvēlīga (1)
6	Temperatūra graudu augšanas periodā (°C)	-	Vidēja (2)
7	Nokrišņu daudzums (cm gadā)	-	Nelabvēlīga (2)
8	Augsnes apstrādes veids	Minimālā	(2)

Mainot augsnes apstrādes veidu un ieviešot minimālo augsnes apstrādes praksi ar jauno tehnikas vienību "Carrier", uzņēmums plāno paaugstināt graudaugu ražas apjomus par 5-7 % gadā. Šis lēmums balstās uz uzņēmuma vadības veiktajām analizēm un prognozēm, kas norāda uz efektivitātes uzlabošanu un līdzekļu ietaupījumu, samazinot augsnes apstrādes izmaksas. Veicot minimālo augsnes apstrādi izsējas norma tiks nedaudz palielināta.

Ņemot vērā to, ka laikapstākļu prognozēšana nākamajam gadam ir sarežģīts, teju neiespējams uzdevums, jo gan temperatūras rādītāji, gan nokrišņu daudzums ir ļoti mainīgi un atkarīgi no daudziem faktoriem, tiek veikts pieņēmums, ka temperatūras rādītāji graudaugu augšanas periodā saglabāsies vidējs, savukārt nokrišņu daudzums būs nelabvēlīgs.

Apkopotie dati par SIA "A" ražu ietekmējošo faktoru rādītājiem 2024. gadā strukturēti IBM SPSS Statistics un pievienoti izveidotajam CHAID lēmumu koku un neironu tīkla modelim, un iegūtie rezultāti apkopoti 7. attēlā.

Ražas_intervāls	Uzņēmuma_nosaukums	Gads	Grauda_svārs	Sēšanas_dziļums	Sēklas_kvalitāte	Augsnes_kvalitāte
\$null\$	SIA A	2024...	Labvēlīga	Vidēja	Labvēlīga	Labvēlīga
Izsējas_norma	Temperatūra	Nokrišņi	Augsnes_apstrāde	\$N-Ražas_intervāls	\$NC-Ražas_intervāls	
Labvēlīga	Vidēja	Nelabvēlīga	Minimāla	Ļoti nelabvēlīga (1,0-1,9)	0.767	

7.attēls. Graudaugu ražas prognozēšanas rezultāti 2024. gadam (autores veidots)

Balstoties uz izveidotā prognozēšanas modeļa rezultātiem par iespējamajiem 2024. gada graudaugu ražas rādītājiem, var secināt, ka ņemot vērā zināmos iespējamajos ražu ietekmējošos faktorus 2024. gada raža ar 77 % ticamības rādītāju arī šajā gadījumā būs ļoti nelabvēlīga, tas ir, robežās 1,0 – 1,9 t/ha.

Lai paaugstinātu izveidotā modeļa prognozēšanas ticamību būtu nepieciešams daudz lielāks un daudzveidīgāks datu apjoms, kas ļautu modelim apmācīties no daudzpusīgākiem datiem, tādējādi būtiski uzlabojot prognozēšanas efektivitāti. Izveidoto lēmumu koka modeli būtu nepieciešams papildināt ar vēl citiem graudaugu ražu ietekmējošiem faktoriem, kas ļautu iegūt detalizētāku novērtējumu par iespējamo graudaugu ražu nākotnē.

Var secināt, ka balstoties uz CHAID lēmumu koka un neironu tīkla modeļa rezultātiem par SIA "A" 2024. gada iespējamajiem ražas apjomiem, kas liecina, ka ar 77 % ticamības rādītāju raža var būt ļoti nelabvēlīga (1,0-1,9 t /ha), nevar apstiprināt uzņēmuma vadības izvirzītās prognozes, ka augsnes apstrādes veida maiņa no tradicionālās uz minimālo uzlabos graudaugu ražas apjomus.

Graudkopības nozares uzņēmumu vadītājiem būtu nepieciešams katru gadu apkopot rādītājus par graudaugu ražu ietekmējošiem faktoriem un graudaugu ražas apjomiem, un, izmantojot jau apmācīto prognozēšanas modeli, kā arī balstoties uz uzņēmuma rīcībā esošajiem

datiem par nākamajiem darbības periodiem, veikt graudaugu ražas prognozi nākamajam gadam, kā rezultātā uzņēmums spētu pielāgoties mainīgajiem apstākļiem, optimizēt pieejamos resursus un veikt nepieciešamās darbības iespējamās ražas apjomu uzlabošanai.

Secinājumi

Graudaugu ražu var ietekmēt tādi faktori kā grauda svars, grauda sēšanas dziļums, sēklas kvalitāte, augsnes kvalitāte, izsējas norma, gaisa temperatūra, nokrišņu daudzums un augsnes apstrādes veids. Balstoties uz izveidoto CHAID lēmumu koku un neironu tīkla modeli ir iespējams prognozēt nākamo periodu graudaugu ražas apjomus.

Summary

Author collected the most important factors affecting grain yield and their impact indicators, as well as analyzed the application of CHAID decision trees and neural networks in the grain growing industry. The data of the organic farming companies of the Latgale region were collected on the harvest volume and the factors affecting it, based on which a decision tree and neural network prediction model was created and trained, as a result of which grain yield forecasts were made for the next periods.

Literatūras un avotu saraksts

1. Lauku tīkls (2022). *Graudkopībā viss tiek plānots par labu ražai*. <https://www.laukutikls.lv/nozares/lauksaimnieciba/raksti/graudkopiba-viss-tiek-planots-par-labu-razai>, sk. 28.10.2023.
2. Blake, J.J., Spink, J.H., Dyer, C. (2003). *Factors affecting cereal establishment and its prediction* Retrieved October, 29, 2023, from https://projectblue.blob.core.windows.net/media/Default/Research%20Papers/Cereals%20and%20Oilseed/rr51_complete_final_report.pdf
3. Kazlauska, D. (2022). *Kā izvēlēties piemērotāko sēklas materiālu*. <https://www.saimnieks.lv/raksts/ka-izveleties-piemerotako-seklas-materialu>, sk. 30.10.2023.
4. NicheAgriculture [n.d.]. *How Rainfall Affects Crop Health*. Retrieved November, 11, 2023, from <https://www.nicheagriculture.com/how-rainfall-affects-crop-health/>
5. Liliane, T.N., Charles, M.S. (2019). *Factors Affecting Yield of Crops*. Retrieved October, 29, 2023, from <https://www.intechopen.com/chapters/70658>
6. Gaile, Z. [n.d.]. *Augsnes apstrādes veidi un augsnes apstrādes sistēmas*. https://www.lbtu.lv/sites/default/files/files/lapas/Augsnes_apstrades_veidi.pdf, sk. 30.10.2023.
7. Kreišmane, S., Popluga, D., Naglis-Liepa, K., Lēnerts, A. (2019). *Augsnes auglības uzlabošana saimniecību ienesīgumam un labvēlīgākam klimatam*. <https://www.saimnieks.lv/raksts/augsgnes-auglibas-uzlabosana-saimniecibu-ienesigumam-un-labveligakam-klimatam>, sk. 30.10.2023.
8. Vaderstad [b.g.]. *Tradicionālā augsnes apstrāde*. <https://www.vaderstad.com/lv/zini-ka/ausgnes-sagatavosana/tradicionala-ausgnes-apstrade/>, sk. 30.10.2023.
9. Vaderstad [b.g.]. *Minimālā augsnes apstrāde*. <https://www.vaderstad.com/lv/zini-ka/ausgnes-sagatavosana/minimala-ausgnes-apstrade/>, sk. 30.10.2023.
10. Vaderstad [b.g.]. *Tiešā sēja*. <https://www.vaderstad.com/lv/zini-ka/ausgnes-sagatavosana/tiesa-seja/>, sk. 30.10.2023.
11. Melece, L. (2020). *Augsnes apstrādes tehnoloģijas*. https://www.arei.lv/sites/arei/files/files/projects/EIP_sanaksme_4.03.2020._AREI_LMelece_Augsnes%20aps trade.pdf, sk. 30.10.2023.
12. Kazlauska, D. (2022). *Kā izvēlēties piemērotāko sēklas materiālu*. <https://www.saimnieks.lv/raksts/ka-izveleties-piemerotako-seklas-materialu>, sk. 30.10.2023.
13. Narayanan, S. (2018). Effects of high temperature stress and traits associated with tolerance in wheat. *Open Access Journal of Science*, Vol.2, Issue 3, p.177-186. Retrieved October, 29, 2023, from <https://doi.org/10.15406/oajs.2018.02.00067>
14. Gammans, M., Merel, P., Ortiz-Bobea, A. (2017). Negative impacts of climate change on cereal yields: statistical evidence from France. *Environmental Research Letters*, Vol. 12, Issue 5. Retrieved October, 29, 2023, from <https://iopscience.iop.org/article/10.1088/1748-9326/aa6b0c>
15. Centrālā statistikas pārvalde (2023). *Lauksaimniecības kultūraugu sējumu kopražā un vidējā ražība – Kultūraugi, Rādītājs un Laika periods*.

- https://data.stat.gov.lv/pxweb/lv/OSP_PUB/START__NOZ__LA__LAG/LAG020/table/tableViewLayout1/,sk.28.10.2023
16. Java [n.d.]. *Crop Yield Prediction Using Machine Learning*. Retrieved November, 02, 2023, from <https://www.javatpoint.com/crop-yield-prediction-using-machine-learning>
 17. Sreerama, A., Sagar, B.M. (2020). A Machine Learning Approach to Crop Yield Prediction. *International Research Journal of Engineering and Technology (IRJET)*, Vol. 07, Issue 05. Retrieved October, 31, 2023, from <https://www.irjet.net/archives/V7/i5/IRJET-V7I51246.pdf>
 18. Burhan, H.A. (2022). *Crop yield prediction by integrating meteorological and pesticides use data with machine learning methods: an application for major crops in turkey*. Retrieved October, 31, 2023, from <https://dergipark.org.tr/en/download/article-file/2558217>
 19. Ramzai, J. (2020). *Simple guide for Top 2 types of Decision Trees: CHAID and CART*. Retrieved November, 23, 2023, from <https://towardsdatascience.com/clearly-explained-top-2-types-of-decision-trees-chaid-cart-8695e441e73e>
 20. Wells, C. (2023). *A guide to CHAID: a decision tree algorithm for data analysis*. Retrieved November, 23, 2023, from <https://www.adience.com/blog/how-to-a-guide-to-chaid-a-decision-tree-algorithm-for-data-analysis/>
 21. Khaki, S., Wang, L. (2019). *Crop Yield Prediction Using Deep Neural Networks*. Retrieved October, 31, 2023, from <https://www.frontiersin.org/articles/10.3389/fpls.2019.00621/full>
 22. Sadenova, M., Beisekenov, N., Varbanov, P.S., Pan, T. (2023). Application of Machine Learning and Neural Networks to Predict the Yield of Cereals, Legumes, Oilseeds and Forage Crops in Kazakhstan. *Agriculture*, Vol. 13, Issue, 6. Retrieved October, 31, 2023, from <https://doi.org/10.3390/agriculture13061195>