



Predição e seleção indireta da massa de grãos da panícula de aveia branca em ambientes com e sem adubação

Prediction and indirect selection of white oat panicle grain mass in environments with and without fertilization

Paola Notargiacomo Ceolin^a, Murilo Vieira Loro^a, Ivan Ricardo Carvalho^b, Giovana Thays Schlösser^a, Dani Antonini Bromberger^a, Angélica Guareschi^a, Vitória Larrosa Bueno^a, Pedro Henrique Pereira Nunes^a

^a Universidade Federal de Santa Maria-UFSM, Centro de Ciências Rurais, Departamento de Fitotecnia. Avenida Roraima, Cidade Universitária, Camobi, Prédio 77, Santa Maria, Rio Grande do Sul, Brasil. CEP: 97105-900. E-mail: ceolinpaola08@gmail.com, muriloloro@gmail.com (*Autor correspondente), diovana.schlosser@acad.ufsm.br, dani.bromberger@ufsm.br, geliguareschi@gmail.com, vitorialarrosabueno@icloud.com, nunesp093@gmail.com.

^b Universidade Regional do Noroeste do Estado do Rio Grande do Sul-UNIJUI, Rua do Comércio, n. 3000, Bairro Universitário, Ijuí, Rio Grande do Sul, Brasil. CEP: 98700-000. E-mail: carvalho.irc@gmail.com.

ARTICLE INFO

Recebido 19 Set 2025

Aceito 09 Nov 2025

Publicado 13 Dez 2025

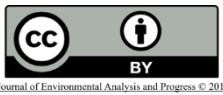
ABSTRACT

Indirect plant selection can be enhanced by easily measured traits that are correlated with the traits of interest. This study aimed to determine whether panicle grain weight can be predicted using easily measured agronomic traits in environments with and without fertilization. Logistic regression analysis was used to evaluate the performance of predictive models in the indirect selection of white oat plants for greater panicle grain weight. Plant height, panicle insertion height, panicle length, panicle weight, panicle grain number, and panicle grain weight were evaluated for 570 white oat plants. Pearson's correlation and partial correlation were performed between the traits. Simple and multiple stepwise forward linear regression were applied to predict NGP and MGP. Logistic regression with cross-validation was used to assess the accuracy of plants selected under selection pressures (5-50%), based on the regression models developed. Panicle grain weight can be predicted using panicle weight, with a coefficient of determination equal to or greater than 0.93, regardless of the presence or absence of fertilization. White oat plants with greater panicle grain weight can be selected simply by weighing the panicle, without the need for threshing, achieving accuracy greater than 85% at selection pressures equal to or greater than 20%, and over 90% at pressures equal to or greater than 35%, regardless of the presence or absence of fertilization.

Keywords: *Avena sativa*, agronomic traits, plant breeding, grain yield, logistic regression.

RESUMO

A seleção indireta de plantas pode ser potencializada por caracteres de fácil mensuração, correlacionados ao caráter de interesse. O estudo objetivou verificar a possibilidade de predizer a massa de grãos da panícula por meio de caracteres agronômicos de fácil mensuração, em ambientes com e sem adubação, e utilizar a análise de regressão logística para avaliar o desempenho de modelos preditores na seleção indireta de plantas de aveia branca com maior massa de grãos da panícula. Avaliaram-se a altura da planta, a altura da inserção da panícula, o comprimento da panícula, a massa da panícula, o número de grãos da panícula e a massa de grãos da panícula, em 570 plantas de aveia branca. Realizaram-se a correlação de Pearson e a correlação parcial entre os caracteres. Aplicaram-se a regressão linear simples e a regressão linear múltipla *stepwise forward* para a predição do NGP e da MGP. A regressão logística com validação cruzada foi utilizada para avaliar a taxa de acerto das plantas selecionadas sob pressões de seleção (5 a 50%), considerando os modelos de regressão desenvolvidos. É possível predizer a massa de grãos da panícula a partir de sua massa, com coeficiente de determinação igual ou superior a 0,93, independentemente da



Journal of Environmental Analysis and Progress © 2016

is licensed under CC BY 4.0

presença ou ausência de adubação. É possível selecionar plantas de aveia branca com maior massa de grãos da panícula por meio da simples pesagem da panícula, sem necessidade de debulha, alcançando precisão superior a 85% em pressões de seleção iguais ou superiores a 20% e acima de 90% em pressões iguais ou superiores a 35%, independentemente da presença ou ausência de adubação.

Palavras-Chave: *Avena sativa*, caracteres agronômicos, melhoramento de plantas, produtividade de grãos, regressão logística.

Introdução

A aveia branca (*Avena sativa*) é uma espécie multifuncional, amplamente utilizada na agricultura devido à sua versatilidade agronômica (Silva, Carvalho & Magano, 2020). Esta gramínea pode ser cultivada para uso forrageiro, na forma direta de pastejo, feno e silagem, bem como planta de cobertura, contribuindo para a proteção e a estruturação do solo. Além disso, os grãos de aveia branca são utilizados na formulação de rações para a alimentação animal, principalmente em sistemas sem oferta de forragem, nos quais sua inclusão favorece o desempenho animal e a eficiência biológica (Pereira et al., 2024). Na alimentação humana, também são valorizados pelos elevados teores de beta-glucano (3,02 a 7,24%) (Bazzer et al., 2025).

A escolha do genótipo e o estádio de desenvolvimento influenciam diretamente a produção de biomassa e a composição química, devendo serem considerados conforme o objetivo produtivo (Silva et al., 2022). A crescente demanda por este cereal exige o desenvolvimento de genótipos superiores, eficientes no uso de recursos e de alto desempenho produtivo. O desenvolvimento de novas cultivares de aveia branca é um desafio para os programas de melhoramento genético, que devem avaliar grandes populações segregantes para selecionar progêneres com maior desempenho agronômico (Borém, Miranda & Fritsche-neto, 2021). Dentre os caracteres agronômicos, a massa de grãos da panícula é um dos principais, frequentemente utilizada como critério de seleção em programas de melhoramento (Loro et al., 2024; Pradebon et al., 2025). No entanto, a avaliação direta da massa de grãos da panícula exige elevada mão de obra, especialmente em grandes populações, nas quais milhares de plantas precisam ser analisadas individualmente. Como alternativa, busca-se identificar caracteres de mensuração fácil e rápida, correlacionados com a massa de grãos da panícula, permitindo a seleção indireta de plantas superiores.

Para avaliar as relações entre os caracteres, métodos estatísticos, como a correlação linear de Pearson, a correlação parcial e a análise de trilha, são amplamente utilizadas. A correlação parcial permite estimar a associação entre dois caracteres eliminando a influência das demais variáveis, proporcionando uma visão mais precisa das relações diretas. Essas ferramentas permitem quantificar as associações entre caracteres, auxiliando na compreensão das inter-relações e na definição de estratégias de seleção mais

eficientes (Cruz, Regazzi & Carneiro, 2014). A análise de regressão linear, tanto simples quanto múltipla, é aplicada para modelar e predizer a massa de grãos da panícula com base em variáveis independentes de fácil mensuração. Esses modelos permitem predizer a variável dependente e, consequentemente, selecionar indiretamente plantas com maior potencial produtivo (Alessi et al., 2021). Essas metodologias são consistentemente aplicadas no estudo das relações entre caracteres na cultura da aveia branca (Meira et al., 2019; Mantai et al., 2020; Schmidt et al., 2023; Treter et al., 2023; Loro et al., 2024). Essas pesquisas indicam que a massa e o número de grãos da panícula podem ser utilizados para selecionar, indiretamente, plantas de aveia branca de maior produtividade de grãos (Schmidt et al., 2023; Treter et al., 2023; Loro et al., 2024).

Contudo, é necessário avaliar o desempenho dos modelos preditivos, considerando não apenas o coeficiente de determinação ou a raiz do erro quadrático médio, mas também a taxa de acertos na seleção de plantas superiores ao aplicar a seleção indireta. Logo, a análise de regressão logística permite classificar as plantas como selecionadas ou não selecionadas com base nos caracteres explicativos. Além disso, permite avaliar a eficácia dos modelos sob diferentes pressões de seleção (Nick & Campbell, 2007). Neste sentido, objetivou-se: (i) verificar se é possível predizer a massa de grãos da panícula por meio de caracteres agronômicos de fácil mensuração em ambientes com e sem adubação; e (ii) utilizar a análise de regressão logística para avaliar o desempenho de modelos preditores na seleção indireta de plantas de aveia branca para maior massa de grãos da panícula.

Material e Métodos

Realizaram-se dois ensaios de uniformidade na mesma área, na safra de 2020, no município de Catuípe, RS, Brasil (28° 20' 14"S, 54° 07' 12"W, 270 m de altitude). Em um dos ensaios, realizou-se a adubação química de base com 250 kg ha⁻¹ de adubo na formulação comercial 05-20-20 (N-P-K), e, no outro, realizou-se o cultivo da aveia branca sem adubação. Cada ensaio foi composto por 19 Unidades Experimentais Básicas (UEB), totalizando 56,525 m². As unidades experimentais básicas foram constituídas por sete fileiras de 2,50 m de comprimento espaçadas em 0,17 m, totalizando 2,975 m². A semeadura da aveia branca (cv. URS Taura) foi realizada em 15 de

abril de 2020. Em ambos os ensaios não se utilizou adubação nitrogenada de cobertura. Os manejos fitossanitários foram adotados para minimizar os efeitos abióticos (pragas e doenças) sobre o desenvolvimento das plantas.

Em plena maturidade fisiológica, em 15 plantas de cada UEB (total de 285 plantas por ensaio), colhidas aleatoriamente, foram mensurados os seguintes caracteres: altura da planta (AP, cm), considerado a distância entre a superfície do solo até a extremidade da panícula; altura da inserção da panícula (AIP, cm), considerado a distância entre a superfície do solo até a inserção da panícula, o comprimento da panícula (CP, cm), a massa da panícula (MP, g), o número de grãos da panícula (NGP, unidade) e a massa de grãos da panícula (MGP, g).

Foram construídos histogramas de frequência e calculados a média e o coeficiente de variação para a AP, AIP, CP, MP, NGP e MGP. Para cada ensaio de uniformidade (com e sem adubação), foram calculados os coeficientes de correlação linear de Pearson e os coeficientes de correlação parcial entre pares de variáveis, e a significância dos coeficientes foi verificada pelo teste *t* de *Student* a 5%. Para cada ensaio de uniformidade (com e sem adubação), realizou-se a regressão linear simples do NGP (y) e do MGP (y) em função da AP (x), AIP (x), CP (x) e MP (x).

Realizou-se o diagnóstico de multicolinearidade em cada uma das três matrizes (com, sem e geral) dos caracteres independentes (AP, AIE, CP e MP), com base no número de (NC). Na ausência de multicolinearidade, estimaram-se os parâmetros do modelo de regressão linear múltipla *stepwise*, considerando o NGP e a MGP como variáveis dependentes e as demais variáveis (AP, AIP, CP e MP) como independentes. Calculou-se o coeficiente de determinação da validação cruzada *leave-one-out* (R^2_{cv}), com $n-1$ observações, avaliando a observação restante. Esse procedimento foi repetido n vezes, excluindo, em cada repetição, uma observação diferente.

Para verificar a adequação dos modelos de regressão linear simples para predição da MGP por meio da MP nos ensaios com e sem adubação, ordenaram-se as plantas em ordem decrescente de MGP e criaram-se 10 cenários com diferentes pressões de seleção de plantas. Os cenários foram os seguintes: pressão de seleção de 5%, 10%, 15%, 20%, 25%, 30%, 35%, 40%, 45% e 50% das plantas, nos ambientes com e sem adubação; ou seja, foram selecionadas 14, 29, 43, 57, 71, 86, 100, 114, 128 e 143 plantas, respectivamente, em cada ambiente. Criou-se uma

coluna para identificar as plantas selecionadas — ou seja, as de maior MGP em cada cenário de pressão de seleção — e as não selecionadas. As plantas selecionadas receberam o valor 1 (um) e as não selecionadas o valor 0 (zero). Assim, para cada ambiente, formaram-se 10 colunas: Pressão de Seleção de 5% (PS5%), 10% (PS10%), 15% (PS15%), 20% (PS20%), 25% (PS25%), 30% (PS30%), 35% (PS35%), 40% (PS40%), 45% (PS45%) e 50% (PS50%). No ambiente com adubação, sob pressão de seleção de 5%, as 14 plantas de maior MGP (selecionadas) foram associadas ao valor 1 (um), enquanto as 271 plantas de menor MGP (não selecionadas) foram associadas ao valor 0 (zero).

A partir disso, para cada ambiente, utilizaram-se modelos de regressão linear entre MGP (y) e MP (x) para gerar a coluna com os valores preditos de MGP (MGP \hat{p}), tanto com quanto sem adubação. Para cada ambiente, aplicou-se a regressão logística com validação cruzada *leave-one-out*, utilizando a MGP \hat{p} como variável independente (x) e as variáveis binárias (0 ou 1) PS5%, PS10%, PS15%, PS20%, PS25%, PS30%, PS35%, PS40%, PS45% e PS50% como variáveis dependentes. Para cada ambiente e variável, calcularam-se a acurácia, o coeficiente kappa, a acurácia da validação cruzada, o coeficiente kappa da validação cruzada, a sensibilidade, a especificidade, o valor predito positivo e o valor predito negativo. Para verificar o índice de acertos, utilizou-se a matriz de confusão. Todas as análises foram realizadas no software R (R Core Team, 2025) por meio dos pacotes *ggplot2* (Wickham, 2016) e *caret* (Kuhn, 2008).

Resultados e Discussão

A massa de grãos da panícula (MGP), o número de grãos da panícula (NGP) e a massa da panícula (MP) apresentaram os maiores coeficientes de variação: 59,69%, 53,63% e 48,72%, respectivamente (Figura 1). Essa amplitude fenotípica é desejável em estudos de predição, pois amplia a capacidade de identificar plantas com desempenho superior. A magnitude da variação dos caracteres MP e NGP foi consistente com os resultados de Dalla Roza et al. (2024), que também relataram variabilidade desses caracteres em linhagens e populações segregantes de aveia branca. Os caracteres morfológicos, como a altura da planta (AP) e a altura de inserção da panícula (AIP), apresentaram $CV \leq 6,64\%$, o que evidencia menor variabilidade fenotípica. Embora importantes em aspectos agronômicos, como colheita e acamamento (Silveira et al., 2021), a contribuição desses caracteres para a predição da produtividade tende a ser baixa (Schmidt et al., 2023; Treter et al., 2023; Loro et al., 2024).

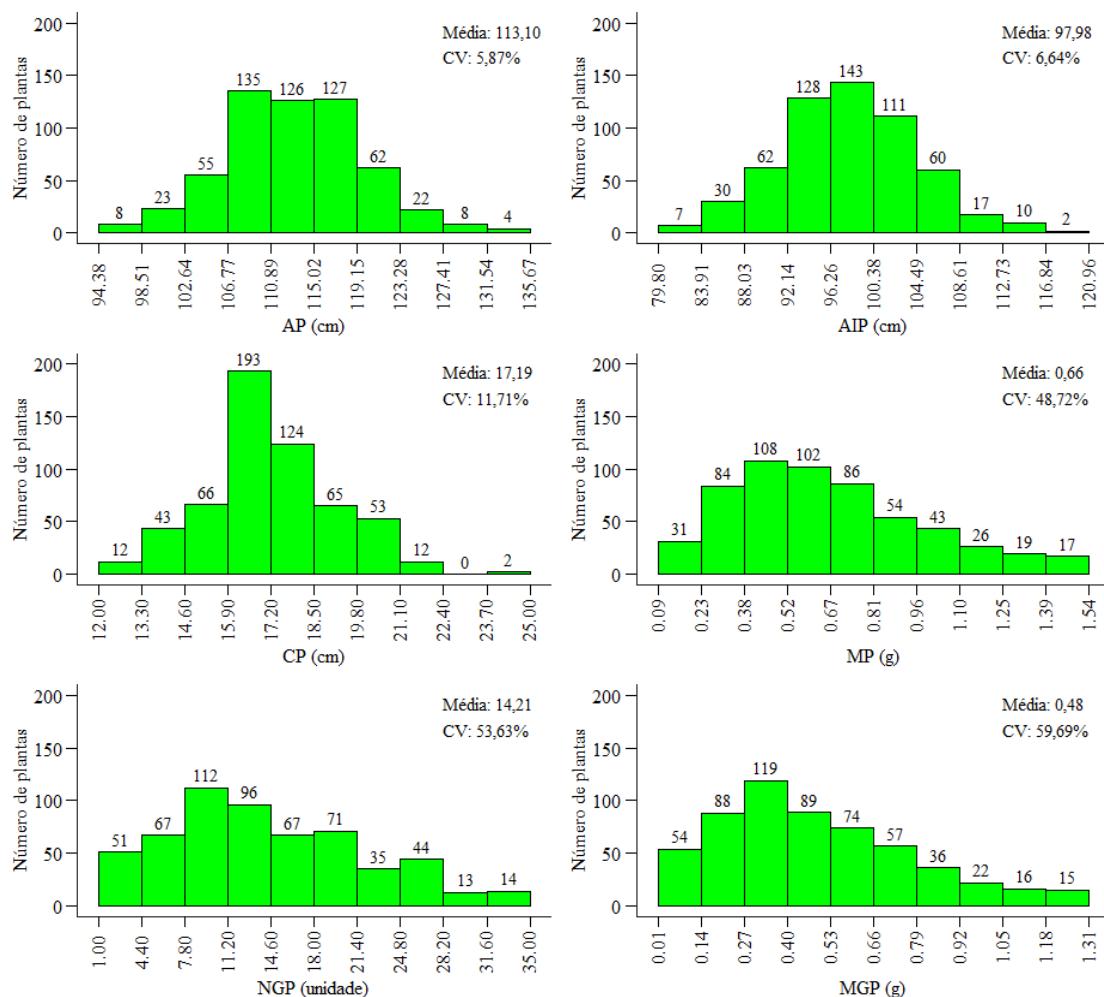


Figura 1. Histogramas de frequência da média e do coeficiente de variação da altura da planta (AP, cm), da altura da inserção da panícula (AIP, cm), do comprimento da panícula (CP, cm), da massa da panícula (MP, g), do número de grãos da panícula (NGP, unidade) e da massa de grãos da panícula (MGP, g) da aveia branca ($n = 570$). Em cada histograma, os limites inferiores da primeira classe e os superiores da última correspondem, respectivamente, aos valores mínimo e máximo. Fonte: Ceolin et al. (2025).

Observou-se uma forte correlação linear de Pearson positiva entre a MGP e a MP ($r = 0,97$) em todos os ambientes, indicando que o caractere MP é um bom preditor da MGP. Essa relação foi reforçada pela análise de correlação parcial (rp), que se manteve alta e positiva (0,89 a 0,93), mesmo após o controle dos efeitos de outros caracteres (Tabela 1). Esse resultado corroborou a forte relação de dependência entre as duas variáveis e está em consonância com a literatura que sugere a possibilidade de seleção indireta de genótipos produtivos por meio dessas características (Schmidt et al., 2023; Treter et al., 2023). Por sua vez,

ao analisar-se a correlação linear de Pearson entre o NGP e a MGP, observou-se uma relação positiva ($r = 0,76$ a 0,82), mas a correlação parcial foi significativamente menor ($rp = 0,24$ e 0,23), indicando que a relação é parcialmente explicada por outros fatores, principalmente pela MP. Portanto, a elevada variabilidade da MGP e sua associação com a MP e o NGP justificaram o uso desses caracteres como variáveis independentes em modelos de regressão subsequentes, fornecendo uma base sólida para a aplicação de modelos preditivos no melhoramento genético.

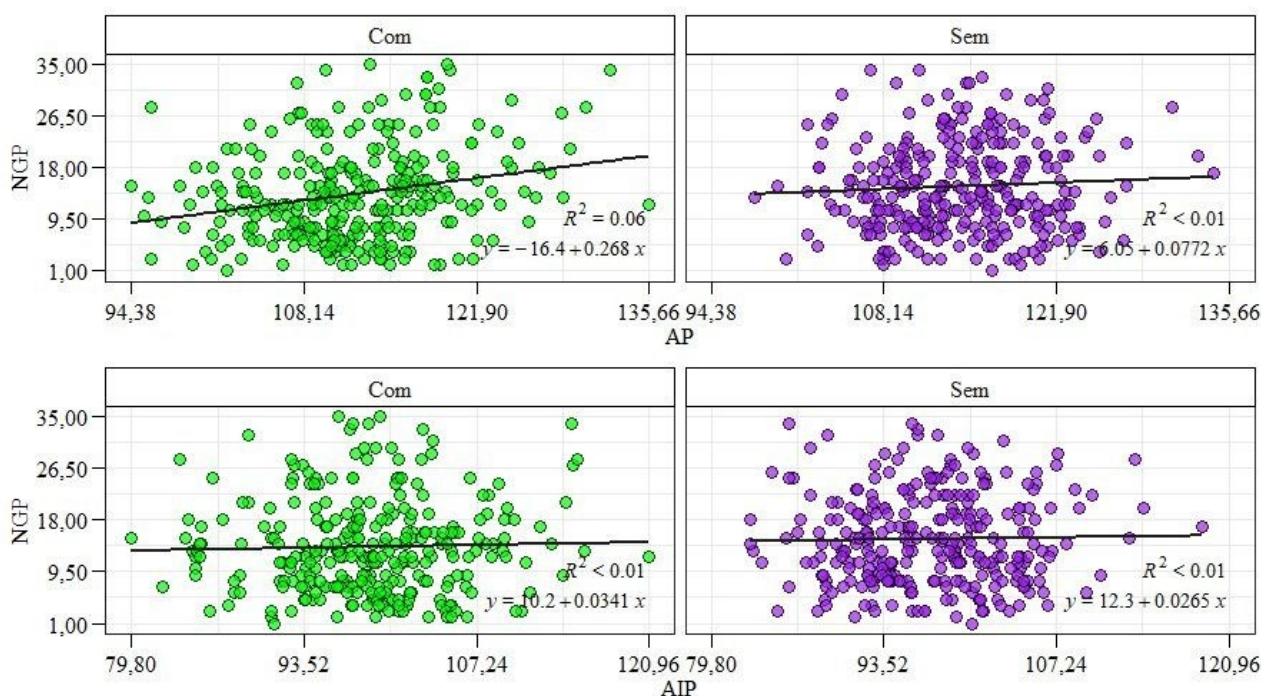
Tabela 1. Coeficientes de correlação linear de Pearson (r) acima da diagonal principal e coeficientes de correlação parcial (rp) abaixo da diagonal principal entre altura da planta (AP, cm), altura da inserção da panícula (AIP, cm), comprimento da panícula (CP, cm), massa da panícula (MP, g), número de grãos da panícula (NGP, unidade) e massa de grãos da panícula (MGP, g) da aveia branca semeada com e sem adubação. Fonte: Ceolin et al. (2025).

Caracteres	AP	AIP	CP	MP	NGP	MGP
Com Adubação ($n = 285$)						
AP		0,92	-0,01	0,30	0,24	0,28
AIP	0,95		-0,09	0,10	0,03	0,09

CP	0,07	-0,09	0,13	0,23	0,10
MP	0,11	-0,09	0,08	0,81	0,97
NGP	0,24	-0,25	0,20	0,10	0,82
MGP	-0,04	0,04	-0,14	0,89	0,24
Sem Adubação (n = 285)					
AP		0,95	0,03	-0,04	0,06
AIP	0,95		0,00	-0,09	0,02
CP	0,00	-0,02		0,19	0,31
MP	0,13	-0,10	0,33		0,97
NGP	0,05	0,01	0,33	0,05	
MGP	-0,11	0,06	-0,38	0,93	0,24
Geral (n = 570)					
AP		0,90	0,03	0,15	0,17
AIP	0,91		-0,06	0,02	0,02
CP	0,06	-0,09		0,15	0,28
MP	0,18	-0,15	0,19		0,97
NGP	0,20	-0,17	0,28	0,09	
MGP	-0,17	0,14	-0,25	0,92	0,23

Em ambos os ambientes, observou-se que a MP foi o preditor mais forte do NGP, com coeficiente de determinação (R^2) entre 0,59 e 0,66 (Figura 2). Esse resultado está em consonância com o estudo de Loro et al. (2024), que apresentou elevada correlação entre a MP e o NGP e o MGP, demonstrando que a MP é uma variável explicativa tanto para o NGP quanto para o MGP em aveia branca. Os caracteres AP, AIP e CP apresentaram baixa capacidade preditiva do NGP, com $R^2 \leq 0,10$. Esses resultados indicam que, embora exista correlação linear entre a AP e a AIP e a NG, esses caracteres não são preditores confiáveis quando considerados isoladamente. Essa limitação também foi

observada por Kurek et al. (2002), que destacaram a baixa contribuição direta desses caracteres para os componentes de rendimento em populações segregantes de aveia. Em ambos os ambientes, a MP foi o preditor mais eficiente da MGP, apresentando os maiores coeficientes de determinação ($R^2 \geq 0,93$; Figura 3). Esses resultados corroboram os obtidos na análise de correlação (Tabela 1), na qual a MP apresentou os maiores coeficientes de correlação linear de Pearson (r) e parcial (r_p) com MGP. Em trigo, Pansera et al. (2022) verificaram um efeito direto positivo da MP sobre a produtividade de grãos, independentemente do ambiente.



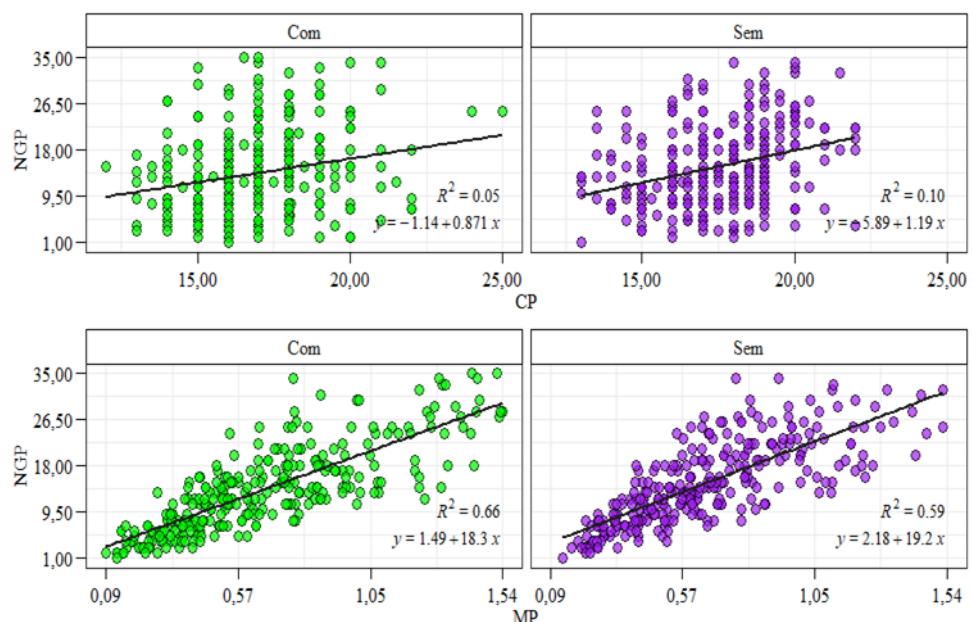
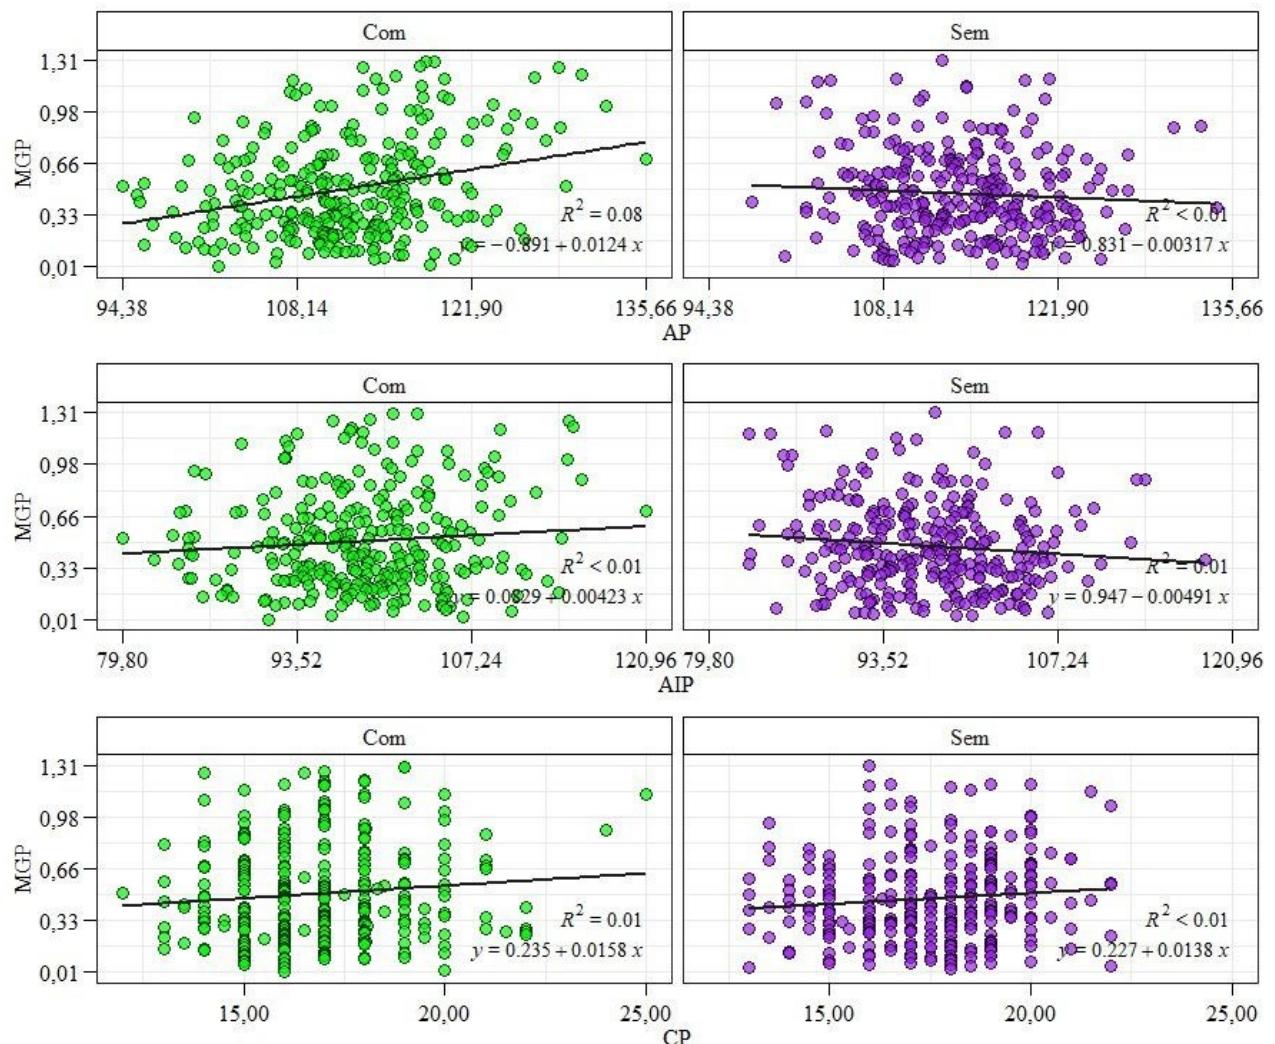


Figura 2. Regressão linear simples entre o número de grãos da panícula (NGP, y) e a altura da planta (AP, cm), a altura da inserção da panícula (AIP, cm), o comprimento da panícula (CP, cm) e a massa da panícula (MP, g) da aveia branca cultivada com e sem adubação. Os parâmetros de todos os modelos de regressão linear simples foram significativos pelo teste t de Student a 5%. Fonte: Ceolin et al. (2025).



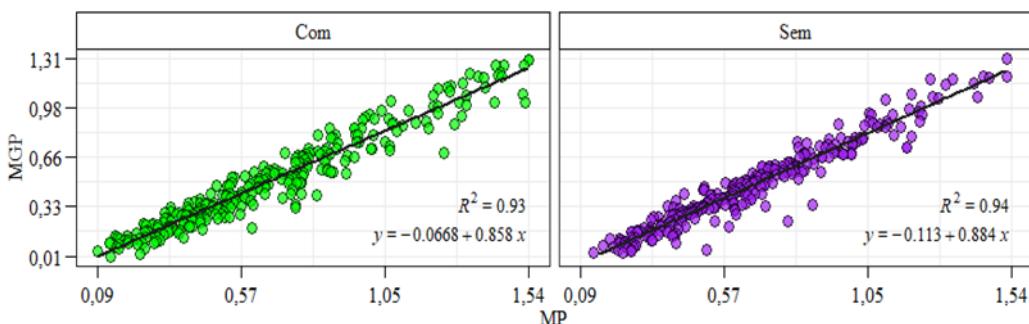


Figura 3. Regressão linear simples entre a massa de grãos da panícula (MGP, g; y) e a altura da planta (AP, cm), a altura da inserção da panícula (AIP, cm), o comprimento da panícula (CP, cm) e a massa da panícula (MP, g) da aveia branca cultivada com e sem adubação. Os parâmetros de todos os modelos de regressão linear simples foram significativos pelo teste t de Student a 5%. Fonte: Ceolin et al. (2025).

Em todos os modelos de regressão linear múltipla *stepwise forward*, a MP foi incluída e explicou a maior parte da variação tanto de NGP quanto de MGP (Tabela 2). O R^2 da regressão múltipla variou de 0,63 a 0,68 e de 0,93 a 0,95 para predição do NGP e do MGP, respectivamente. O R^2_{cv} foi similar ao R^2 , o que revela a alta capacidade de predição do modelo, especialmente da MGP, com a utilização de novos dados. O R^2 dos modelos de regressão linear

múltipla para a predição da MGP foi semelhante ao dos modelos de regressão linear simples, que utilizavam apenas a MP como preditora da MGP. Logo, é preferível utilizar modelos parcimoniosos, ou seja, com menor número de parâmetros. Assim, os modelos de regressão linear simples, com a MP como variável independente para prever a MGP, são os mais adequados e práticos.

Tabela 2. Regressão linear múltipla *stepwise forward* para predição do número de grãos da panícula (NGP, unidades) e da massa de grãos da panícula (MGP, g) por meio da altura da planta (AP, cm), da altura da inserção da panícula (AIP, cm), do comprimento da panícula (CP, cm) e da massa da panícula (MP, g) da aveia branca cultivada com e sem adubação. Fonte: Ceolin et al. (2025).

Modelo	NGP			MGP		
	Com	Sem	Geral	Com	Sem	Geral
Intercepto	-6,230644	-19,117368	-14,428887	-0,066819	0,236620	0,166042
AP	-	-	0,270064	-	-0,001333	-0,003640
AIP	-	0,106149	-0,232139	-	-	0,002828
CP	0,471364	0,650290	0,544622	-	-0,011775	-0,007665
MP	17,910718	18,637214	17,394282	0,857919	0,897368	0,886908
R^2	0,68	0,63	0,66	0,93	0,95	0,94
R^2_{cv}	0,67	0,62	0,65	0,93	0,94	0,94

As estimativas dos parâmetros de todos os modelos de regressão linear múltipla foram significativas pelo teste t de Student a 5%.
 R^2 : coeficiente de determinação ajustado; R^2_{cv} : coeficiente de determinação da validação cruzada *leave-one-out*.

A evidência de forte associação entre MP e MGP, observada tanto na correlação linear de Pearson quanto nos modelos preditores, e mesmo sob diferentes condições de adubação, reforça a confiabilidade da MP como variável explicativa. Isso permite aplicar esses modelos para selecionar, indiretamente, plantas de maior MGP por meio da simples pesagem da MP em populações segregantes de aveia branca. Assim, os seguintes modelos lineares: $y = -0,0668 + 0,858x$ (com adubação) e $y = -0,113 + 0,884x$ (sem adubação) fornecem uma base sólida para a predição da MGP, com elevada precisão, sendo aplicáveis a programas de melhoramento voltados a ganhos genéticos indiretos. No entanto, a verificação do modelo com base na precisão teórica, no R^2 ou em outras estatísticas de precisão, como a raiz do erro

quadrático médio, não fornece uma avaliação prática desses modelos para a seleção correta das melhores plantas. Logo, utilizou-se a regressão logística para avaliar a capacidade dos modelos de regressão linear simples de selecionar adequadamente as plantas de maior MGP, por meio da MP, sob diferentes pressões de seleção.

A sensibilidade aumentou gradualmente, evidenciando maior capacidade do modelo para identificar as plantas verdadeiramente superiores (Figura 4 e Tabela 3). Isso indica que a redução da pressão de seleção torna o modelo mais inclusivo, favorecendo a recuperação de um número maior de plantas superiores, porém, ao custo de incluir mais plantas inferiores. Como exemplo, obteve-se sensibilidade superior a 85% quando a pressão de

seleção foi igual ou superior a 20%, independentemente do ambiente.

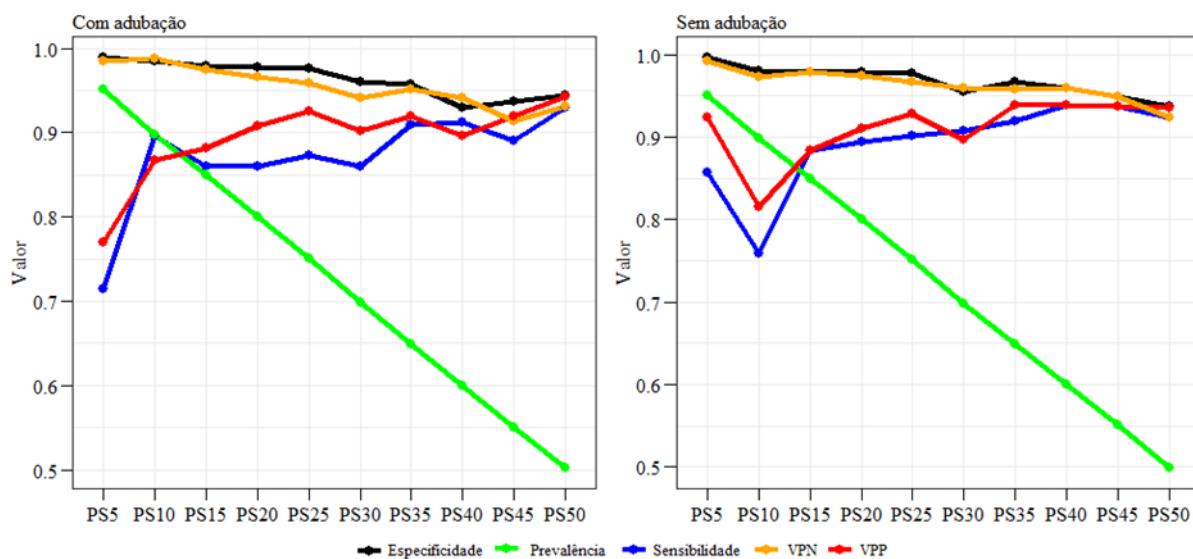


Figura 4. Evolução dos parâmetros de desempenho dos modelos de regressão logística para a seleção de plantas de aveia branca com base na massa de grãos da panícula predita (MGP_p), considerando diferentes pressões de seleção: especificidade, prevalência, sensibilidade, valor preditivo negativo (VPN) e valor preditivo positivo (VPP) para pressão de seleção de 5% (PS5%), 10% (PS10%), 15% (PS15%), 20% (PS20%), 25% (PS25%), 30% (PS30%), 35% (PS35%), 40% (PS40%), 45% (PS45%) e 50% (PS50%) para ambiente com e sem adubação. Fonte: Ceolin et al. (2025).

Tabela 3. Matriz de confusão dos modelos de regressão logística para a seleção de plantas de aveia branca com base na massa de grãos da panícula predita (MGP_p), considerando diferentes pressões de seleção: 5% (PS5%), 10% (PS10%), 15% (PS15%), 20% (PS20%), 25% (PS25%), 30% (PS30%), 35% (PS35%), 40% (PS40%), 45% (PS45%) e 50% (PS50%) em ambiente com e sem adubação. 0: plantas não selecionadas, 1: plantas selecionadas. Fonte: Ceolin et al. (2025).

Pressão de Seleção	Predita/Real	Com adubação		Sem adubação	
		0	1	0	1
PS5	0	268	4	270	2
	1	3	10	1	12
PS10	0	252	3	251	7
	1	4	26	5	22
PS15	0	237	6	237	5
	1	5	37	5	38
PS20	0	223	8	223	6
	1	5	49	5	51
PS25	0	209	9	209	7
	1	5	62	5	64
PS30	0	191	12	190	8
	1	8	74	9	78
PS35	0	177	9	179	8
	1	8	91	6	92
PS40	0	159	10	164	7
	1	12	104	7	107
PS45	0	147	14	149	8
	1	10	114	8	120
PS50	0	135	10	133	11
	1	8	132	9	132

Isso indica que, ao utilizar o modelo de regressão linear simples para seleção indireta da MGP por meio da MP, com pressão de seleção igual ou superior a 20%, mais de 85% das plantas superiores serão selecionadas corretamente. No ambiente com adubação, verificou-se um aumento gradual do valor preditivo positivo (VPP) à medida que a pressão de seleção diminuía. Considerando o ambiente sem adubação, o VPP apresentou uma queda inicial, seguida de um acréscimo gradual. Esse comportamento pode estar relacionado à maior heterogeneidade da área sem adubação, o que dificulta a identificação precisa das plantas superiores.

Os modelos apresentaram elevada acurácia nas maiores pressões de seleção (PS5% a PS15%), com valores $\geq 0,9614$ em ambos os ambientes (Tabela

4). Isso indica uma elevada capacidade de classificação correta das plantas com base na variável MGPr. Com um Kappa elevado ($> 0,80$), que considera o ajuste pelo acaso, a concordância nesses cenários foi classificada como substancial a quase perfeita. De Cól, Coelho & Del Ponte (2024) aplicaram essa técnica para prever surtos de brusone em trigo, utilizando variáveis climáticas contínuas, alcançando altos valores de acurácia (AUC de 0,89 a 0,91). No entanto, como o objetivo do modelo é identificar corretamente as plantas superiores, a acurácia não é o melhor parâmetro, pois considera todas as previsões, tanto positivas quanto negativas. Neste estudo, há desequilíbrio entre as classes (0 e 1), o que indica que a acurácia pode ser alta mesmo que o modelo erre na classe de maior interesse (1).

Tabela 4. Evolução dos parâmetros de desempenho dos modelos de regressão logística para a seleção de plantas de aveia branca com base na massa de grãos da panícula previda (MGPr), considerando diferentes pressões de seleção: acurácia, coeficiente kappa, acurácia da validação cruzada, coeficiente kappa da validação cruzada, sensibilidade e especificidade para pressão de seleção (PS) de 5% (PS5%), 10% (PS10%), 15% (PS15%), 20% (PS20%), 25% (PS25%), 30% (PS30%), 35% (PS35%), 40% (PS40%), 45% (PS45%) e 50% (PS50%) para ambiente com e sem adubação. PS =Pressão de Seleção. Fonte: Autores (2025).

PS	Acurácia	Kappa	Acurácia cv	Kappa cv	Sensibilidade	Especificidade
Com adubação						
PS5	0,9754	0,7279	0,9754	0,7279	0,7143	0,9889
PS10	0,9754	0,8677	0,9719	0,8510	0,8966	0,9844
PS15	0,9614	0,8479	0,9579	0,8325	0,8605	0,9793
PS20	0,9544	0,8546	0,9474	0,8322	0,8596	0,9781
PS25	0,9509	0,8662	0,9474	0,8573	0,8732	0,9766
PS30	0,9298	0,8312	0,9298	0,8312	0,8605	0,9598
PS35	0,9404	0,8688	0,9403	0,8687	0,9100	0,9568
PS40	0,9228	0,8397	0,9158	0,8251	0,9123	0,9298
PS45	0,9158	0,8293	0,9158	0,8293	0,8906	0,9363
PS50	0,9368	0,8737	0,9368	0,8737	0,9296	0,9441
Sem adubação						
PS5	0,9895	0,8834	0,9789	0,7746	0,8571	0,9963
PS10	0,9579	0,7624	0,9579	0,7624	0,7586	0,9805
PS15	0,9649	0,8631	0,9649	0,8631	0,8837	0,9793
PS20	0,9614	0,8786	0,9614	0,8786	0,8947	0,9781
PS25	0,9579	0,8864	0,9579	0,8864	0,9014	0,9766
PS30	0,9404	0,8589	0,9403	0,8589	0,9070	0,9548
PS35	0,9509	0,8917	0,9474	0,8836	0,9200	0,9676
PS40	0,9509	0,8977	0,9509	0,8977	0,9386	0,9591
PS45	0,9439	0,8865	0,9438	0,8865	0,9375	0,9490
PS50	0,9298	0,8597	0,9298	0,8596	0,9231	0,9366

Embora os R^2 dos modelos de regressão linear simples entre a MGP e a MP tenham sido elevados, deve-se ter cautela ao utilizar esses modelos para a seleção indireta de plantas com maior MGP por meio da MP, pois a proporção de plantas superiores corretamente selecionadas variou conforme a pressão de seleção. Assim, o melhorista pode selecionar plantas de aveia branca de maior MGP apenas pela pesagem da panícula, sem necessidade de debulha. Essa estratégia alcança mais de 85% de precisão em

pressões de seleção a partir de 20% e supera 90% quando iguais ou superiores a 35%, independentemente da adubação. Na prática, o modelo de previsão pode ser aplicado em gerações iniciais de populações segregantes (F2 e F3), em que se utilizam pressões de seleção menores devido à manifestação de efeitos de dominância e de sobredominância. Dessa forma, a abordagem adotada neste estudo mostra-se uma ferramenta eficiente e de fácil implementação

para acelerar os ganhos genéticos em populações de aveia branca por meio da seleção indireta.

Conclusão

É possível predizer a massa de grãos da panícula a partir da massa da panícula, com coeficiente de determinação igual ou superior a 0,93, independentemente da presença ou ausência de adubação.

É possível selecionar plantas de aveia branca com maior massa de grãos da panícula por meio da simples pesagem da panícula, sem necessidade de debulha, alcançando precisão superior a 85% em pressões de seleção iguais ou superiores a 20% e acima de 90% em pressões iguais ou superiores a 35%, independentemente da presença ou ausência de adubação.

Referências

- Alessi, O.; Mantai, R. D.; Silva, J. A. G.; Bárta, R. L.; Pansera, V.; Kraisig, A. R.; Berlezi, J. D.; Matter, E. M. 2021. Regressão linear múltipla envolvendo variáveis biológicas e ambientais na simulação de indicadores da composição química de grãos de aveia. Proceeding Series of the Brazilian Society of Computational and Applied Mathematics, 8, 010469-1-010469-7. <https://doi.org/10.5540/03.2021.008.01.0469>
- Bazzer, S. K.; Oliveira, G.; Fiedler, J. D.; Nandety, R. S.; Jannink, J. L.; Caffe, M. 2025. Genomic strategies to facilitate breeding for increased β -Glucan content in oat (*Avena sativa* L.). BMC Genomics, 26, 26-35. <https://doi.org/10.1186/s12864-024-11174-5>
- Borém, A.; Miranda, G. V.; Fritsche-Neto, R. 2021. Melhoramento de plantas. 384p.
- Cruz, C. D.; Regazzi, A. J.; Carneiro, P. C. S. 2014. Modelos biométricos aplicados ao melhoramento genético. 668p.
- Roza, J. P. D.; Carvalho, I. R.; Pradebon, L. C.; Loro, M. V.; Sangiovo, J. P.; Bruisma, G. M. W.; Silva, J. A. G. 2024. Genetic dissimilarity and agronomic performance of mutant and recombinant white oat progenies, 23, 554-564. <https://doi.org/10.5965/223811712342024554>
- De Cól, M.; Coelho, M.; Del Ponte, E. M. 2024. Weather-Based Logistic Regression Models for Predicting Wheat Head Blast Epidemics. Plant Disease, 108, (11), 2206-2213. <https://doi.org/10.1094/pdis-11-23-2513-re>
- Fernandes, A. A. T.; Figueiredo Filho, D. B.; Rocha, E. C.; Nascimento, W. S. 2020. Leia este artigo se você quiser aprender regressão logística. Revista de Sociologia e Política, 28, (74), 1-20. <https://doi.org/10.1590/1678-987320287406en>
- Kuhn, M. 2008. Building Predictive Models in R Using the caret Package. Journal of Statistical Software, 28, (5), 1-26. <https://doi.org/10.18637/jss.v028.i05>
- Kurek, A. J.; Carvalho, F. I. F.; Oliveira, A. C.; Cargnini, A.; Marchioro, V. S.; Lorencetti, C. 2002. Coeficiente de correlação entre caracteres agronômicos e de qualidade do grão e sua utilidade na seleção de plantas em aveia. Ciência Rural, 32, (3), 371-376. <https://doi.org/10.1590/S0103-84782002000300002>
- Loro, M. V.; Carvalho, I.; Megiolaro Junior, G. L.; Pradebon, L. C.; Sangiovo, J. P.; Roza, J. P. D.; Bandeira, W. J. A. 2024. Relationships between agronomic traits and characterization of the white oat ideotype for cultivation with and without chemical fertilization. Revista Thema, 23, (2), 532-544. <https://doi.org/10.15536/thema.V23.2024.532-544.3621>
- Mantai, R. D.; Silva, J. A. G.; Binelo, M. O.; Sausen, A. T. Z. R.; Rossi, D. S.; Corso, J. S. 2020. Nitrogen management in the relationships between oat inflorescence components and productivity. Brazilian Journal of Agricultural and Environmental Engineering, 24, 385-393. <https://doi.org/10.1590/1807-1929/agriambi.v24n6p385-393>
- Meira, D.; Meier, C.; Olivoto, T.; Follmann, D. N.; Rigatti, A.; Lunkes, A.; Marchioro, V. S.; Souza, V. Q. 2019. Multivariate analysis revealed genetic divergence and promising traits for indirect selection in black oat. Brazilian Journal of Agricultural Sciences, 14, 1-7. <https://doi.org/10.5039/agraria.v14i4a6514>
- Nick, T. G.; Campbell, K. M. 2007. Logistic regression. Topics in Biostatistics, 404, 273-301, 2007. https://doi.org/10.1007/978-1-59745-530-5_14
- Pansera, V.; Silva, J. A. G.; Alessi, O.; Basso, N. C. F. 2022. Dose and form of nitrogen supply in the relationship dynamics of wheat ear components with yield in cropping systems. Genetics and Molecular Research, 21, (2), GMR19024036.
- Pereira, L. B.; Machado, D. S.; Alves Filho, D. C. A.; Brondani, I. L.; Adams, S. M.; Silva, M. B.; Cocco, J. M.; Maidana, F. M.; Klein, J. L.; Volpatto, R. S. 2024. Substitution of corn grain with white oat grain in non-forage diets for feedlot beef cattle. Brazilian Journal of Animal Science, 53, e20230138. <https://doi.org/10.37496/rbz5320230138>
- Pradebon, L. C.; Carvalho, I. R.; Silva, J. A. G.; Loro, M. V.; Roza, J. P. D. 2025. White oat progenies based on the agronomic ideotype due to response to environmental stimulus. Ciência Rural, 55, (3), e20230195. <http://doi.org/10.1590/0103-8478cr20230195>

- R core team. 2025 R: a language and environment for statistical computing. Vienna: R Foundation for Statistical Computing. Disponível em: <https://www.R-project.org>
- Schmidt, A. L.; Carvalho, I. R.; Pradebon, L. C.; Silva, J. A. G.; Loro, M. V.; Sfalcin, I. C.; Donadel, P. E.; Segatto, T. A.; Alban, A. A.; Challiol, M. A. 2023. Organic system and reflections on white oat grain productivity components. *Agronomy Science and Biotechnology*, 9, 1-12. <https://doi.org/10.33158/ASB.r188.v9.2023>
- Silva, E. L.; Secco, D.; Marins, A. C.; Bassegio, D.; Castro, M. B. S. 2022. Soil physical characteristics and corn grain yield as a function of cover crops. *Research, Society and Development*, 11, (1), e21511124823. <https://doi.org/10.33448/rsd-v11i1.24823>
- Silva, J. A. G.; Carvalho, I. R.; Magano, D. A. (Org.). 2022. A cultura da aveia: da semente ao sabor de uma espécie multifuncional. 404p.
- Silveira, D. C.; Basso, S. M. S.; Ebone, L. A.; Caverzan, A.; Machado, J. M.; Schaeffer, A. H.; Folchini, J. A.; Lângaro, N. C. 2021. Morphological traits of stem to indirect selection of resistance to lodging in *Avena sativa* L. *Journal of Crop Science and Biotechnology*, 25, 39-50. <https://doi.org/10.1007/s12892-021-00111-7>
- Treter, R. J. R.; Furlan, R. D. P.; Carvalho, I. R.; Pradebon, L. C.; Sangiovo, J. P.; Sfalcin, I. C.; Loro, M. V.; Silva, J. A. G.; Alban, A. A.; Challiol, M. A.; Ferreira, L. L. 2023. Agronomic performance of white oats in organic system in the northwest region of Rio Grande do Sul. *Agronomy Science and Biotechnology*, 9, (1), 1-11. <https://doi.org/10.33158/ASB.r189.v9.2023>
- Wickham, H. 2016. *ggplot2: elegant graphics for data analysis*. New York: Springer-Verlag. 260p. <https://doi.org/10.1007/978-3-319-24277-4>