

# Ferramentas de Business Intelligence Aplicada no Capim - Elefante

Jessica Costa de Oliveira<sup>1</sup>, Emerson Augusto Priamo Moraes<sup>2</sup>, Ricardo Costa Pinto e Santos<sup>3</sup>

<sup>1</sup>Instituto Federal de Educação, Ciência e Tecnologia do Sudeste de Minas Gerais -  
Campus Juiz de Fora – MG – Brasil

<sup>2</sup>Orientador - Instituto Federal de Educação, Ciência e Tecnologia do Sudeste de Minas  
Gerais - Campus Juiz de Fora – MG – Brasil

<sup>3</sup>Coorientador - Instituto Federal de Educação, Ciência e Tecnologia do Sudeste de  
Minas Gerais - Campus Juiz de Fora – MG – Brasil

{jessikacostajf@gmail.com, emerson.moraes@ifsudestemg.edu.br,  
ricardo.santos@ifsudestemg.edu.br}

**Abstract.** *This work aims to evaluate the phenotypic characteristics of elephantgrass for selection of superior genotypes through the use of high throughput phenotype to be able to measure promising forage species for the production of biomass. The experiments were carried out in the Experimental Field of Coronel Pacheco of Embrapa Gado de Leite. For this, statistical methods, data visualization tools and Artificial Intelligence techniques were used to obtain greater data accuracy and relevant results.*

**Resumo.** *Este trabalho tem como objetivo avaliar as características fenotípicas do capim-elefante para seleção de genótipos superiores através do uso de fenotipagem de alto rendimento seja capaz de mensurar as espécies de forrageiras promissoras para produção de biomassa. Os experimentos foram realizados no Campo Experimental de Coronel Pacheco da Embrapa Gado de Leite. Para tal, foram utilizados métodos estatísticos, ferramentas de visualização de dados e técnicas de Inteligência Artificial para obter maior precisão dos dados analisados e resultados relevantes.*

## 1. Introdução

Este presente trabalho teve início na Embrapa Gado de Leite, considerada referência em relação ao desenvolvimento pesquisas e soluções inovadoras na cadeia do leite. Além disso, tem acumulado considerável conhecimento com outras vertentes de pesquisa, em especial, o capim-elefante. A Embrapa, tem colaborado grandemente para aperfeiçoamento de técnicas nos programas de melhoramento genético e fenotipagem de alto rendimento para seleção de genótipos superiores.

Os avanços biotecnológicos e das ferramentas genômicas, tem contribuído constantemente para implementação de novas técnicas nos programas de melhoramento genético, refletindo como fator relevante para a pesquisa e futuras aplicações no mercado, beneficiando os agricultores e consumidores. O uso da fenotipagem de alto

rendimento é uma excelente alternativa para aprimorar os programas de melhoramento existentes. Através da utilização de câmeras de alta resolução e sensores mensura-se de forma rápida e precisa grande quantidade de genótipos em curto de intervalo de tempo (Figura 1).

Além disso, existe potencial desenvolvimento metodológico a utilização de índices específicos na fenotipagem de alto rendimento, tais como: VARI (*visible atmospherically resistant index*) e GLI (*green leaf index*).



**Figure 1.** Campo Experimental de Coronel Pacheco

**Fonte:** Embrapa

O capim-elefante é uma espécie de rápido crescimento vegetativo, alto potencial energético e de baixo custo. Os programas de melhoramento genético e fenotipagem em larga escala são essenciais para seleção de genótipos promissores de capim-elefante e assim aumentar a produção de biomassa. Pode-se utilizar para seguintes finalidade: pastejo, feno e silagem, nutrição animal e produção de biomassa (Figura 2).



**Figure 2.** Produção de Silagem

**Fonte:** Embrapa

## 2. Revisão da Literatura

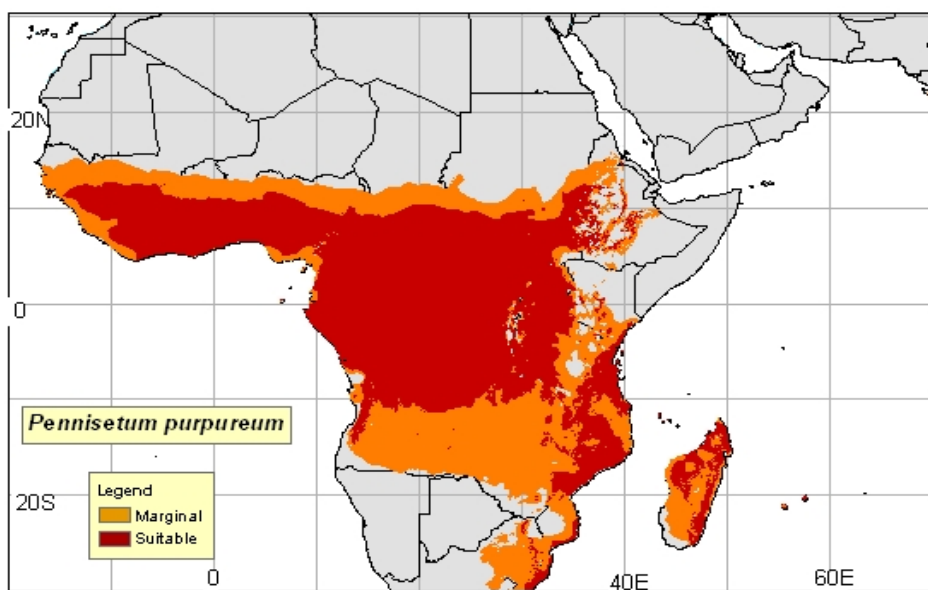
Para levantamento bibliográfica deste trabalho foram utilizadas pesquisas nas seguintes plataformas: Periódicos da Capes, Google Acadêmico e Acervo bibliotecário da Embrapa. A string de busca consistiu nas seguintes palavras-chaves: “*Pennisetum purpureum* Schum” AND “fenotipagem de alto rendimento”; “visible atmospherically resistant index” AND “green leaf index” AND “capim-elefante”

### 2.1. Capim-elefante

O capim-elefante é uma gramínea perene pertencente a uma extensa área do continente africano, tem grande adaptação às regiões de clima tropical com precipitação acima de 1000 mm anuais (PEREIRA et al., 2010, LIRA et al. 2010). O capim-elefante é uma excelente alternativa de custo relativamente baixo (CÓSER et al., 2000; PEREIRA et al., 2010).

Pertence à família Poaceae, sub-família Panicoideae, tribo: Paniceae, gênero: *Pennisetum* L. Rich e espécie: *P. purpureum*, Schumacher (STEBBINS e CRAMPTON, 1961).

É uma gramínea perene, de rápido crescimento vegetativo, podendo alcançar de 3 a 5 metros de altura.



**Figure 3.** Áreas de adaptação de capim-elefante - Centro de diversidade na África

**Fonte:** Embrapa

### 2.2. Melhoramento genético de capim-elefante

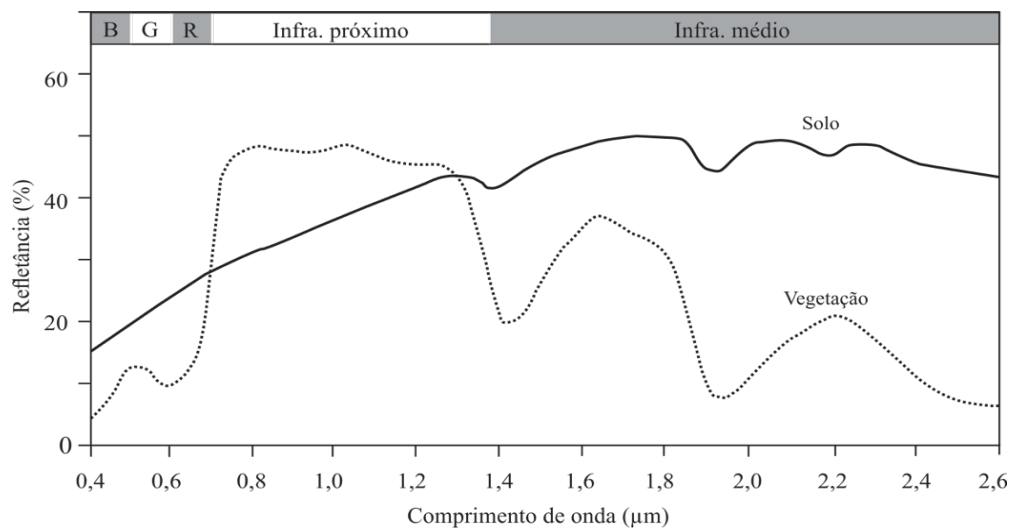
Os programas de melhoramento de capim-elefante, estão voltados, principalmente, para os caracteres agrônômicos, produção de matéria seca, obtenção de maior produtividade e resistentes às pragas, minimizando o custo produção e uso de fertilizantes (MAZZARELLA, 2011) para garantir obtenção de genótipos cada vez promissores (PEREIRA et al., 2008).



**Figure 4.** Laboratório de Genética Vegetal

**Fonte:** Embrapa

### 2.3. Índices Espectrais



**Figura 5.** Perfis de refletância de vegetação e solo exposto ao longo da seção do espectro representada pelo azul (B), verde (G), vermelho (R) e infravermelhos próximo e médio

**Fonte:** Adaptado de Lillesand, Kiefer e Chipman (2014)

#### 2.3.1. Índice VARI (*Visible Atmospherically Resistant Index*)

Monitora o índice de área foliar em culturas de plantas em estágio tardio, conforme a expressão abaixo:

$$\text{VARI} = (R_g - R_r) / (R_g + R_r - R_b) \text{ (GITELSON et al., 2002)}$$

#### 2.3.2. Índice GLI (*Green Leaf Index*)

Avalia a cobertura do dossel, conforme a expressão abaixo:

$$\text{GLI} = (2 \cdot R_g - R_r - R_b) / (2 \cdot R_g + R_r + R_b) \text{ (LOUHAICHI et al., 2001)}$$




em que: Rr, Rg e Rb referem-se a refletância do dossel nas faixas ou bandas espectrais do vermelho, verde e azul.

### 3. Metodologia

Para atingir a proposta deste trabalho que é demonstrar a importância dos índices VARI e GLI nos experimentos, principalmente, envolvendo culturas de capim-elefante o quanto pode influenciar positivamente para seleção genótipos superiores e colaborar para aumento da produção de biomassa, através de metodologias tradicionais e técnicas de Inteligência Artificial apresentadas a seguir.

Os experimentos foram realizados no Campo Experimental em Coronel Pacheco, sob coordenação da Embrapa Gado de Leite, no delineamento de blocos ao acaso com três repetições, de acordo com as cores indicadas (Figura 6), no qual foram avaliados 22 genótipos de capim-elefante na base de dados da Embrapa, conhecido como Banco Ativo de Germoplasma de Capim-Elefante – BAGCE.

Baseado em informações disponibilizadas pela Embrapa Gado de Leite no ano de 2018, o banco de germoplasma contém em torno 173 acessos de capim-elefante



**Figura 6.** Croqui Experimental. Campo Experimental da Embrapa Gado de Leite em Coronel Pacheco – MG

**Fonte:** Embrapa



**Figura 7.** Plataforma Alelo (Base de Dados dos Bancos Ativos de Germoplasma da Embrapa)

**Fonte:** Embrapa

Foram utilizados duas metodologias de fenotipagem, primeira metodologia, em relação à fenotipagem de alto rendimento, os genótipos foram avaliados por meio de câmeras de alta resolução e sensores a bordo da plataforma VANT (Veículo aéreo não tripulado), permitindo avaliar, principalmente, os índices VARI e GLI. A segunda, em relação à fenotipagem tradicional, os genótipos foram avaliados de acordo com suas características: peso verde total (PVT), peso seco total (PST), altura (ALT), vigor (VIG) e matéria seca (%MS).

Seguindo estudos anteriores, foram realizadas análises estatísticas por meio do software ASReml (GILMOUR et al., 2015). Além disso, foi utilizado o modelo de tendência para o procedimento REML/BLUP (Restricted Maximum Likelihood/Best Linear Unbiased Prediction), conforme o modelo abaixo:

$$Y = Xb + Zg + \varepsilon$$

em que:  $y$  é o vetor de dados fenotípicos arranjados em linhas e colunas,  $b$  é o vetor de média geral com a matriz de incidência  $X$ ,  $g$  é o vetor de efeitos fixo de genótipos com matriz de incidência  $Z$ .  $\varepsilon$  é um vetor de erro aleatório.

Posteriormente, um levantamento bibliográfico envolvendo aplicações de ferramentas e técnicas Inteligência Artificial voltada para áreas pecuária e agricultura para complementar os resultados obtidos por meio da fenotipagem.

Optou-se por utilizar como instrumento de trabalho o *Orange*, devido a versatilidade, usabilidade, *open-source*, permite construção visualização de dados, aprendizado de máquina, *data mining* (mineração de dados) e plotagem de gráficos de forma rápida.

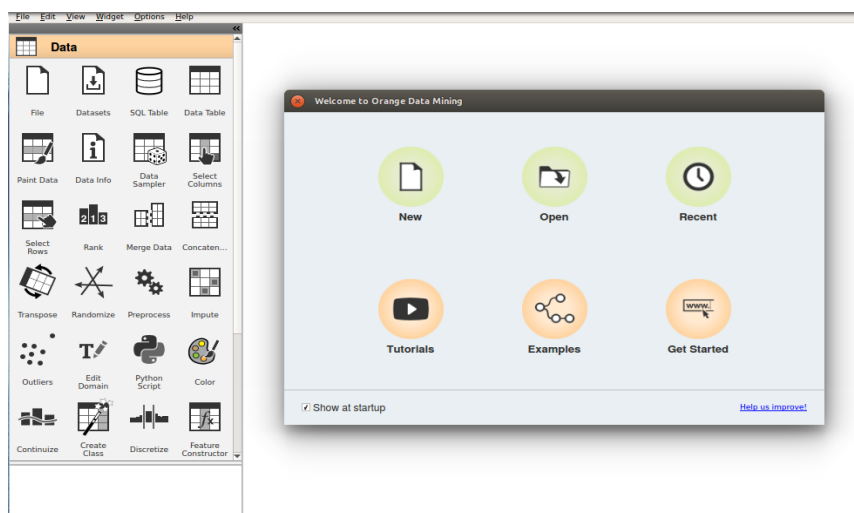
Os dados foram organizados em três grupos cada um contendo os índices VARI e GLI como fatores primordiais para execução dos algoritmos, de acordo com características fenotípicas: VIG, PST e PVT, respectivamente.

Após a separação do experimento por grupos, de acordo com a características fenotípicas do capim-elefante, utilizamos o software *Orange* para fazer os treinamentos através de diversos algoritmos de aprendizado máquina. Os algoritmos abordados foram escolhidos, seguindo sua particularidade que poderia trazer de validação e interpretação para o conjunto de dados, levando em consideração seus benefícios e malefícios.

Por último, foram selecionados os seguintes algoritmos: *Neural Network*, *Random Forest*, *SVM (Support Vector Machine)*, *AdaBoost*, *KNN (K- Nearest Neighbors)* e *Linear Regression*. O objetivo do uso destes algoritmos de aprendizado de máquina citado anteriormente, é exatamente avaliar o desempenho de cada um separadamente e identificar o que apresenta grande relevância para o experimento, considerando os índices VARI e GLI. Os algoritmos utilizados para desenvolvimento deste trabalho foram: *SVM* e *Linear Regression*.

### 3.1. *Orange*

O *Orange* é um software de código aberto, baseado em aprendizagem de máquina e modelagem preditiva que destina a criação de gráficos, visualização de dados interativos, mineração de dados, análise exploratória e cálculos estatísticos. Um software que permite realizar diversas tarefas de *Data Science* e utilizar a biblioteca *Python*.



**Figura 8.** Exemplo do Software *Orange*

## 3.2. Aprendizado de Máquina

### 3.2.1. *SVM (Support Vector Machine)*

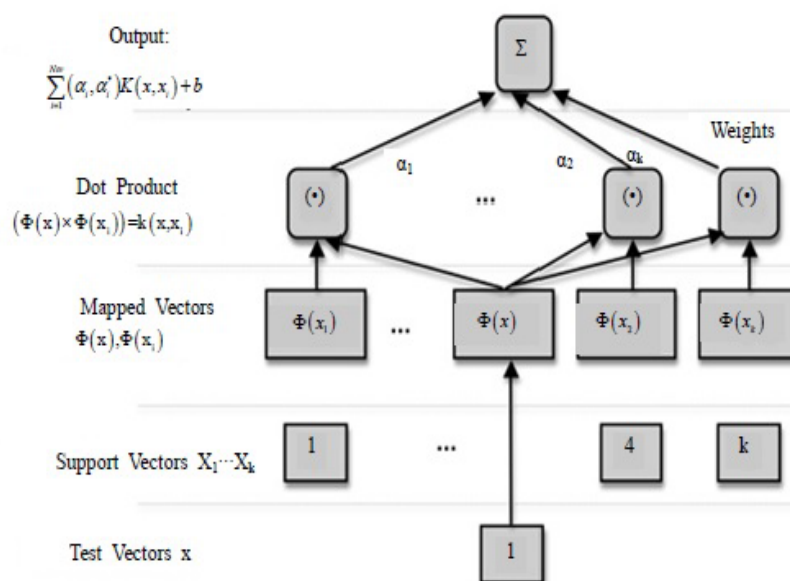
Os *SVMs* (Máquinas de vetores de suporte) são métodos de *Machine Learning* baseados em aprendizado supervisionado que analisam os dados e reconhecem padrões, usados para classificação e regressão. Além disso, pode ser em diversas áreas, por exemplo, análises de imagens e bioinformática.

*“Os resultados desta técnica são comparáveis ou superiores aos obtidos por outros algoritmos já estabelecidos, como as Redes Neurais Artificiais (Lorena e Carvalho, 2007; Al-Anazi e Gates, 2010; Awad e Khana, 2015).”*

“O Support Vector Machine (SVM) representa uma generalização do algoritmo, desenvolvido na Rússia nos anos 60, *Generalized Portrait*, sendo baseado em vetores-suporte como estratégia de aprendizado, solidamente fundamentado na teoria de aprendizado estatístico, ou teoria VC (Vapnik-Chervonenkis) (LIMA, 2004).”

“Os algoritmos de aprendizagem de máquina (SVM) têm como objetivo a determinação de limites de decisão que produzam uma separação ótima entre classes por meio da minimização dos erros (Vapnik, 1995).”

“Recentemente, o SVM foi utilizado na área de sensoriamento remoto com relativo sucesso (Brown et al., 2000; Melgani e Bruzzone, 2004).”



**Figura 9.** Exemplo de Arquitetura SVM

**Fonte:** (SOTOMAYOR et al., 2013)

### 3.2.2 Linear Regression (Regressão Linear)

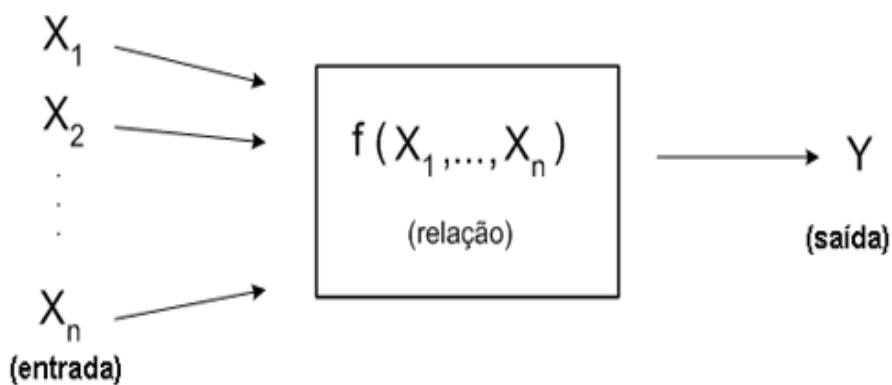
A Regressão Linear é um modelo matemático que permite identificar a relação entre uma variável dependente e outras variáveis independentes, ou seja, é um modelo capaz de verificar o comportamento empírico de uma variável pode influenciar no comportamento da outra.

“A análise estatística de regressão apenas modela qual relacionamento matemático pode existir, se existir algum [HOFFMANN, 2006].”

“Para Ferrão (2003), os modelos de regressão são técnicas estatísticas utilizadas para investigar a relação existente entre as variáveis abordados no estudo. Chama-se  $y$  a variável desfecho e  $x$  a variável preditora. A equação a seguir pode ser definida como um modelo de regressão linear simples ou univariado:  $y_i' = \alpha + \beta x_i + \epsilon_i$ .”

#### Processo





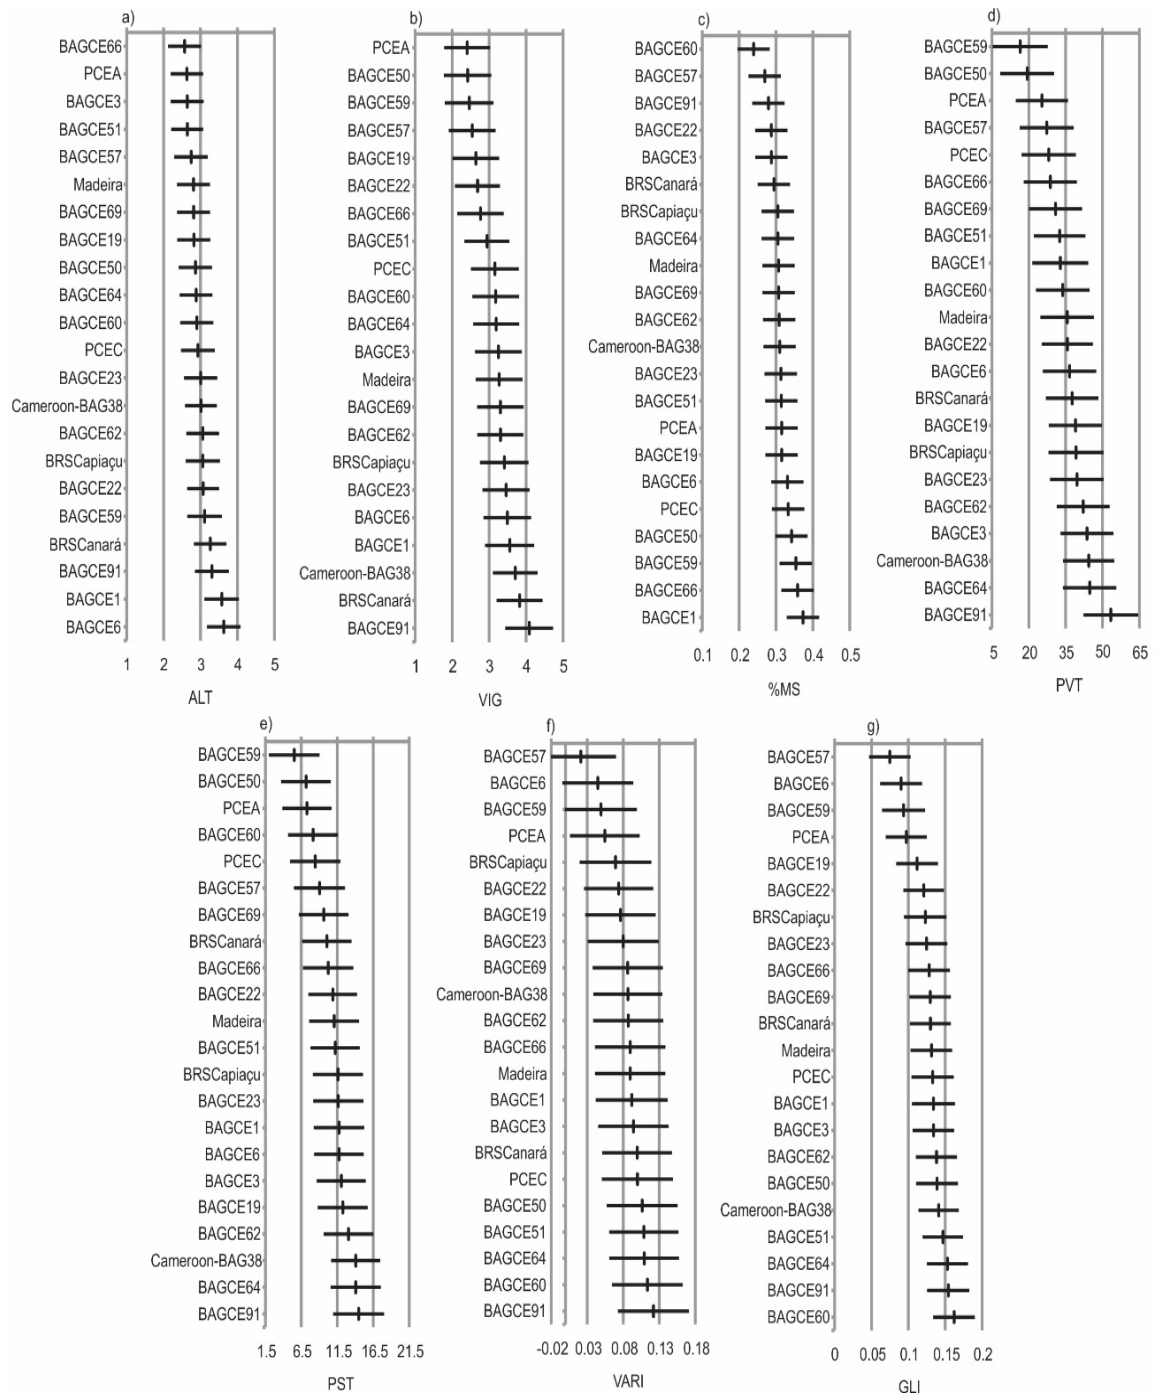
**Figura 10.** Representação dos Processos

#### **4. Análise e Discussão dos Resultados**

Observa-se, em relação à fenotipagem tradicional, para característica altura (ALT), destacou-se os genótipos BAGCE 6, BAGCE 1 e BAGCE 91 (Fig 10a). Para o vigor (VIG), os genótipos BAGCE 91, BRS Canará e Cameroon (Fig 10b) são os que obtiveram maiores notas. Já a para característica porcentagem de matéria seca %MS, destacou-se os genótipos BAGCE 1, BAGCE 66 e BAGCE 59 (Fig 10c). Por último, o peso verde total (PVT) e peso seco total (PST), os genótipos BAGCE 91 e BAGCE 94 foram os mais promissores (Fig 10d e Fig 10e), respectivamente.

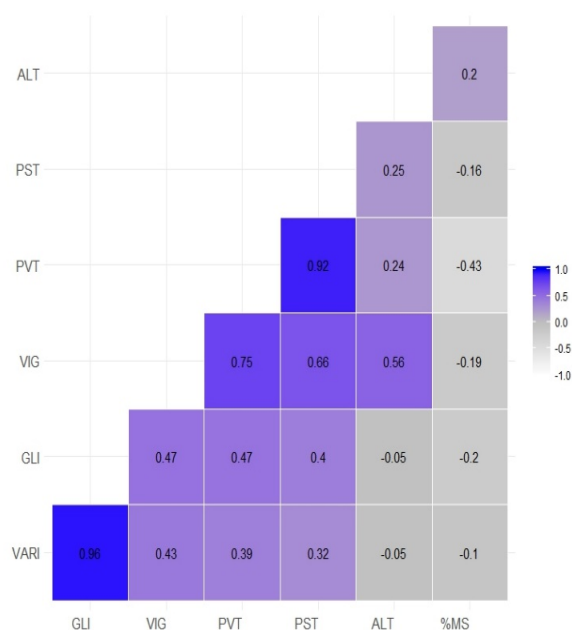
Já para a fenotipagem de alto rendimento, nota-se que no índice VARI, o destaque foi apenas o genótipo BAGCE 91 (Fig 10f). Para o índice GLI, os genótipos BAGCE 60, BAGCE 91 e BAGCE 64 (Fig 10g).

Ressalta-se, que o capim-elefante com pigmentação arroxeadada o BAGCE 57 é um fator perturbador para determinar os índices.



**Figura 11.** Intervalos de confiança construídos para a média dos genótipos para as características altura de plantas (ALT, m), vigor fenotípico (VIG, nota), porcentagem de matéria seca (%MS), peso verde total (PVT, kg.ha-1), peso seco total (PVT, kg.ha-1), índice de resistência visual atmosférica (VARI) e índice de folha verde (GLI).

**Fonte:** Embrapa



**Figura 12.** Correlações simples de Person entre as características agrônômicas altura de plantas (ALT, m), vigor fenotípico (VIG, nota), porcentagem de matéria seca (%MS, %), peso verde total (PVT, kg ha<sup>-1</sup>), peso seco total (PVT, kg ha<sup>-1</sup>) e os índices de resistência visual atmosférica (VARI) e de folha verde (GLI).

**Fonte:** Embrapa

Conforme as análises estatísticas por meio do software ASReml, obtivemos um efeito significativo correspondente a probabilidade ( $p < 0,05$ ), o que indica que as médias dos genótipos diferentes entre si (Tabela 1).

Infer-se que existe diferença entre os genótipos para os índices VARI e GLI (Figura 9), portanto, tem potencial para aplicações de capim-elefante pela seleção genótipos superiores e melhorados geneticamente.

Segundo a tabela abaixo, é importante ressaltar que o GLI foi o mais preciso o agrega relevância para utilização em fenotipagem de alto rendimento, enquanto que o VARI, devido à baixa precisão em relação as características levam a resultados inconsistentes.

**Tabela 1.** Análise estatística para as características altura de plantas (ALT, m), vigor fenotípico (VIG, nota), porcentagem de matéria seca (%MS), peso verde total (PVT, kg.ha-1), peso seco total (PVT, kg.ha-1), índice de resistência visual atmosférica (VARI) e índice de folha verde (GLI).

Fonte de variação	GL	Características						
		ALT	VIG	%MS	PVT	PST	VARI	GLI
Genótipos	21	137.97***	168.24***	39.80**	83.28***	40.76**	121.67***	197.33***
Resíduo	44	0.218	0.441	0.002	120.9	10.94	0.002	0.001
CVe (%) <sup>a</sup>		13.07	18.68	10.48	33.52	28.20	50.50	21.04

CVe (%) = coeficiente de variação experimental; \*\*,\*\*\*, significativo a 1 e 5%, respectivamente.

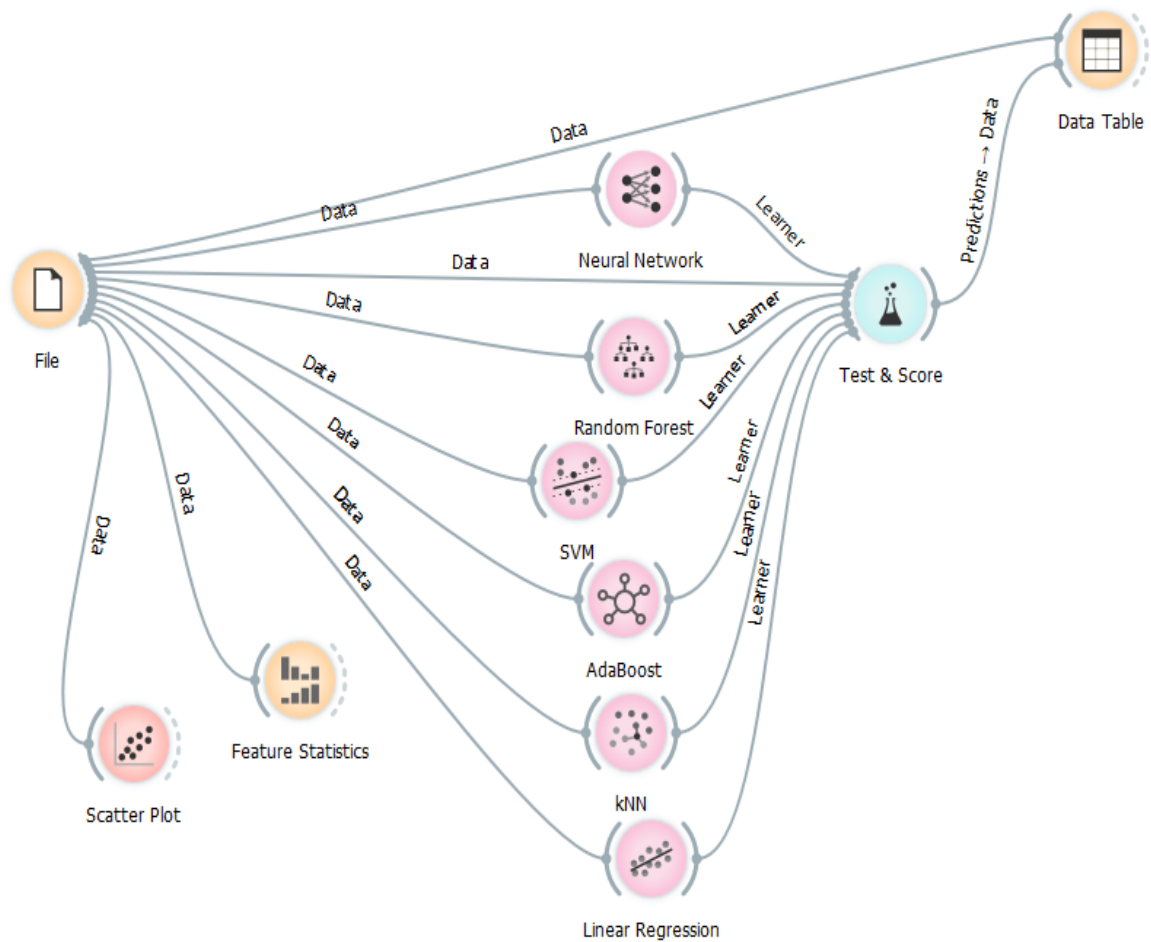


**Figura 13.** Índice VARI (resistência visual atmosférica) à esquerda e GLI (índice de folha verde) à direita na fenotipagem de alto rendimento de capim-elefante. Coronel Pacheco-MG

**Fonte:** Embrapa

A figura 12 representa a estrutura desenhada no *Orange* para execução dos algoritmos de aprendizado máquina e plotagem dos gráficos.





**Figura 14.** Estrutura no Orange

<b>Legenda</b>	
<b>MSE</b>	Mede a média dos quadrados dos erros ou desvios.
<b>RMSE</b>	Raiz quadrada da média aritmética dos quadrados de um conjunto de números.
<b>MAE</b>	Usado para medir previsão ou previsão aproximada de eventuais resultados.
<b>R2</b>	Interpretado como proporção de variância na variável dependente que é previsível da variável independente.

**Figura 15.** Legenda do Test & core

Conforme as figuras, nota-se que a implementação de diferentes algoritmos de aprendizado máquina teve um papel importante, principalmente, quando se refere ao comportamento do capim-elfante com pigmentação arroxçada no experimento. Tal comportamento demonstra uma pequena interferência do roxo, o que indica que pode ser um fator perturbador.

Infer-se para a característica vigor (Figura 16), o destaque foi para o algoritmo SVM, conforme o resultado obtido pelo MAE= 0,401.

Method	MSE	RMSE	MAE	R2
kNN	0.298	0.546	0.442	0.233
SVM	0.253	0.503	0.401	0.347
Random Forest	0.297	0.545	0.444	0.234
Neural Network	0.264	0.514	0.406	0.320
Linear Regression	0.264	0.514	0.406	0.320
AdaBoost	0.409	0.640	0.526	-0.055

**Figura 16.** Test & Score do vigor (VIG).

Entretanto, para as características peso verde e seco (Figura 17 e 18), o destaque foi para o algoritmo Linear Regression (Regressão Linear) para ambas, conforme os resultados obtidos pelos MAE = 8,227.

Method	MSE	RMSE	MAE	R2
kNN	142.521	11.938	9.603	0.003
SVM	117.293	10.830	8.549	0.180
Random Forest	142.317	11.930	9.057	0.004
Neural Network	112.177	10.591	8.227	0.215
Linear Regression	112.177	10.591	8.227	0.215
AdaBoost	192.496	13.874	10.114	-0.347


**Figura 17.** Test & Score do peso verde (PVT).

Method	MSE	RMSE	MAE	R2
kNN	11.178	3.343	2.802	0.073
SVM	10.350	3.217	2.556	0.141
Random Forest	12.171	3.489	2.752	-0.010
Neural Network	10.205	3.195	2.554	0.153
Linear Regression	10.206	3.195	2.554	0.153
AdaBoost	17.812	4.220	3.187	-0.478


**Figura 18.** Test & Score do peso seco (PST).

Conforme exposto nos gráficos de dispersão abaixo, em relação às características fenotípicas e os índices VARI e GLI em cultivares de capim-elefante. A fim de


investigar a influência dos índices para seleção dos genótipos superiores. Novamente, o GLI é o mais preciso, de acordo com os pontos dos gráficos está menos disperso em relação VARI para todas características analisadas.



**Figura 19.** Plotagem do gráficos vigor com índice VARI à esquerda e GLI à direita.



**Figura 20.** Plotagem do gráficos peso verde com índice VARI à esquerda e GLI à direita.



**Figura 21.** Plotagem do gráficos peso seco com índice VARI à esquerda e GLI à direita.

## 5. Conclusão e Trabalhos Futuros

Definimos como metodologia para o desenvolvimento deste trabalho atrelar as seguintes áreas de conhecimento: tecnologia e genética vegetal. Atualmente, conhecida pelo nome de fenotipagem de alto rendimento, basicamente com o uso recursos tecnológicos e implementação de inovações, cujo o principal objetivo é aumentar os ganhos genéticos e reduzir custo.

Para atingir os resultados esperados deste trabalho, buscamos revisar a literatura para identificar a respeito das melhorias que vem sendo utilizadas de mais moderno nos programas de melhoramento genético e fenotipagem em cultivares de capim-elefante e como tem sido adesão da tecnologia no campo agrícola.

No tange da pesquisa investigamos a influência dos índices VARI e GLI e as características fenotípicas através dos programas de melhoramento genético e aplicações de algoritmos de aprendizado de máquina, o índice GLI tem maior precisão (CVe = 21%) em relação ao experimento e por conta disso pode ser utilizado como instrumento na fenotipagem em larga escala em cultivares de capim-elefante.

Além disso, as correlações entre os índices VARI e GLI e as características de fenotípicas do capim-elefante equivale aos seguintes resultados: VIG e GLI (0,47), PVT e GLI (0,47) e VIG e VARI (0,43), o que indica que o índice GLI é o mais correlacionado com produção de biomassa.

O aperfeiçoamento das técnicas de fenotipagem e programas de melhoramento e utilização de novos equipamentos tecnológicos poderá ser fator que irá contornar as limitações apresentadas pelos índices VARI e GLI na fenotipagem de alto rendimento do capim-elefante.



Para futuros trabalhos sugere-se estudo a respeito das implementações de outros índices espectrais, por exemplo, *NDVI*, *GDVI*, *SAVI* e *PRI* para enxergar seus potenciais e limitações em cultivares de capim-elefante.

## **6. Agradecimentos**

Em primeiro lugar, gostaria de agradecer em especial ao Juarez Campolina Machado e toda equipe da Embrapa Gado de Leite pelo apoio para desenvolvimento deste trabalho. Ao meu orientador e coorientador Emerson Augusto Priamo Moraes e Ricardo Costa Pinto e Santos, respectivamente. Também ao IF Sudeste MG – Campus Juiz de Fora pela oportunidade de poder adquirir tantos conhecimentos multidisciplinares e além do contato com a comunidade externa através projetos de pesquisa e extensão, contribuindo para minha formação pessoal e profissional.

## 7. Referências

- MONTEIRO, F. A. Adubação para o estabelecimento e manutenção de capim-elefante. In: CARVALHO, L. A.; CARVALHO, M. M.; MARTINS, C. E.; VILELA, D. (Ed.). **Capim-elefante: produção e utilização**. Coronel Pacheco: Embrapa Gado de Leite, 1994. p. 49-79.
- GILMOUR, A.R.; GOGEL, B.J.; CULLIS, B.R.; WELHAM, S.J.; THOMPSON, R. **ASReml user guide. Release 4.0** VSN International Ltd, Hemel Hempstead, UK, 2015.
- GITELSON, A.A., KAUFMAN, Y.J., STARK, R., RUNDQUIST, D. Novel algorithms for remote estimation of vegetation fraction. **Remote Sensing of Environment**, v. 80, p. 76–87, 2002.
- LOUHAICHI, M., BORMAN, M.M., JOHNSON, D.E. Spatially located platform and aerial photography for documentation of grazing impacts on wheat. **Geocarto International**, v. 16, p. 65–70, 2001.
- ROCHA, J.R.A.S.C.; MACHADO, J.C.; CARNEIRO, P.C.S.; ET AL. Bioenergetic potential and genetic diversity of elephantgrass viamorpho-agronomic and biomass quality traits. **Industrial Crops and Products**, v. 95, p.485–492, 2017.
- GEBREMEDHIN, A.; BADENHORST, P.E.; WANG, J.; ET AL. Prospects for Measurement of Dry Matter Yield in Forage Breeding Programs Using Sensor Technologies. **Agronomy**. v. 9, p. 1–19, 2019.
- PEREIRA, A. V.; AUAD, A. M.; LEDO, F. J. S.; BARBOSA, S. *Pennisetum purpureum*. In: FONSECA, D. M. da; MARTUSCELLO, J. A. (Org.). **Plantas Forrageiras**. Viçosa: Editora UFV, 2010. v. 1, p. 197-219.
- GIGLIOTI, É. A.; SUMIDA, C. H.; CANTERI, M. G. Fenômica de resistência a doenças. In: FRITSCHÉ-NETO, R.; BORÉM, A. (Eds.). Fenômica: Como a fenotipagem de próxima geração está revolucionando o melhoramento de plantas. 1. ed. Viçosa: UFV, 2016. p. 148–178.
- PRADO, André Alves; SILVA FILHO, José Eugênio da; GASPARG, Tiago Roberto Vitorino. **Integração do bussiness intelligence como ferramenta de auxílio na tomada de decisões nos sistemas enterprise resource planning**. Revista de Administração da Fatea, Lorena, v. 4, n. 4, p.93-109, dez. 2011.
- CRUZ, C.D.; VENCOSKY, R. Comparação de alguns métodos de análise dialélica. **Revista Brasileira de Genética**, v.12, p.425-438, 1989.
- ROCHA, J.R.A.S.C.; MACHADO, J.C.; CARNEIRO, P.C.S.; ET AL. Bioenergetic potential and genetic diversity of elephantgrass viamorpho-agronomic and biomass quality traits. **Industrial Crops and Products**, v. 95, p.485–492, 2017.
- GEBREMEDHIN, A.; BADENHORST, P.E.; WANG, J.; ET AL. Prospects for Measurement of Dry Matter Yield in Forage Breeding Programs Using Sensor Technologies. **Agronomy**. v. 9, p. 1–19, 2019.
- Orange Canvas. Disponível em: <<https://orange.biolab.si/>> Acesso em: 27 mar 2019.
- Scikit Learn. Disponível em: <<https://scikit-learn.org/stable/modules/svm.html>> Acesso em: 28 mar. 2019.

GONÇALVES, Lóren Pinto Ferreira. **Avaliação de Ferramentas de Mineração de Dados como fonte de dados relevantes para a tomada de decisão**. 2001. 104 f. Dissertação (Mestrado em administração) – Escola de Administração, Universidade federal do Rio Grande do Sul, Porto Alegre, 2001.

TAN, P.N; STEINBACK, M.; KUMAR, V. **Introdução ao Data Mining**. Rio de Janeiro: ed. Ciência Moderna, 2009.

WITTEN, I. H.; FRANK, E.; HALL, M. A. **Data Mining: Practical machine learning tools and techniques**. 3. ed.. Morgan Kaufmann, 2011.

CASTANHEIRA, Luciana Gomes. **Aplicação de Técnicas de Mineração de Dados em Problemas de Classificação de Padrões**. Belo Horizonte: UFMG, 2008.

Awad, M., Khanna, R. 2015. Efficient Learning Machines: Theories, Concepts, and Applications for Engineers and System Designers. ApresOpen. 248 pp

Tartakovsky, D.M., Wohlberg, B., Guadagnini, A. 2007. Nearest-neighbor classification for facies delineation. Water Resources Research, Vol. 43.